



UNIVERSIDAD DE CHILE  
FACULTAD DE CIENCIAS FÍSICAS Y MATEMÁTICAS  
DEPARTAMENTO DE INGENIERÍA ELÉCTRICA

DETECCIÓN DE CONDICIÓN FALLA DE ENCOLAMIENTOS DE CAMBIOS DE  
ESTADO DE MÓVILES PREPAGO A TRAVÉS DE DIVERGENCIA DE  
KULLBACK-LEIBLER

TESIS PARA OPTAR AL GRADO DE MAGÍSTER EN INGENIERÍA DE REDES DE  
COMUNICACIONES

MILFLEN MUNDTSEN TORRES HUIRCAMAN

PROFESOR GUÍA:  
PATRICIO PARADA SALGADO

MIEMBROS DE LA COMISIÓN:  
NICOLAS BELTRAN MATURANA  
JORGE SILVA SÁNCHEZ  
NELSON CLAVERO LARA (Profesor Invitado)

SANTIAGO DE CHILE  
AGOSTO 2012

## Resumen

La industria de telefonía móvil de prepago chilena concentra al 70% de los clientes móviles de los principales operadores en el país. Este servicio utiliza un proceso de descuento y abono en línea que permite rebajar en forma casi instantánea los créditos consumidos al utilizar los servicios de voz y datos habilitados en el terminal, y abonar el crédito correspondientes cuando se hace aplica una recarga prepagada, que son las operaciones más habituales que se aplican para cambiar el estado de operación de un terminal móvil prepago.

La dinámica de estas transiciones depende de manera íntima de la operatividad del sistema computacional que administra y ejecuta estos cambios. Su arquitectura, del tipo servidor-cola de comandos, utiliza una filosofía *first-in first-out* (FIFO) para procesar cada comando asociado a la transición de estado que debe aplicarse sobre cada terminal de la red. Este sistema de administración de comandos puede colapsar si la demanda por cambios de estado aumenta en forma repentina y supera la capacidad de procesamiento del servidor. Ello tiene como consecuencia un aumento desmedido del tamaño de la cola de comandos, lo que a su vez, puede originar problemas en las prestaciones de telecomunicaciones dentro de la red y pérdidas monetarias al operador al dejar fuera de línea el sistema de cobro.

Este fenómeno, que se denomina encolamiento, es controlado en los sistemas comerciales utilizando alarmas por umbral, las que indican a los administradores del sistema la necesidad de activar las contramedidas necesarias para restablecer el correcto funcionamiento del sistema. Sin embargo, el valor de este umbral es fijado sin utilizar necesariamente criterios de optimalidad de desempeño, lo que reduce la eficiencia en la operación técnica y comercial del servicio.

La hipótesis de trabajo de esta investigación es que el uso un umbral “duro” puede ser mejorado al emplear un enfoque que incorpore la historia del proceso que describe la longitud de la cola de comandos, como el basado en las distribuciones de probabilidad de las condiciones de operación normal y de encolamiento. Para validar esta conjetura, se diseñó un detector de encolamientos basado en la divergencia de Kullback-Leibler, la que permite comparar la distribución instantánea de las observaciones con las correspondientes a la condición de operación normal y de encolamiento.

La metodología empleada para validar esta tesis se basó en la simulación computacional de las transiciones de estado descrita mediante el uso de una cadena de Markov de 3 estados, que se utilizó para cuantificar la operación del detector y compararla con las métricas asociadas a la detección dura mediante umbrales. Las métricas de desempeño empleadas fueron el porcentaje de errores de tipo I (no detección) y de tipo II (falso positivo), las cuales fueron calculadas en forma empírica en ambos detectores. Además, el funcionamiento del detector fue validado con datos reales de operación a partir de un registro de 14 meses de observaciones.

Los resultados obtenidos avalan la hipótesis planteada, en el sentido que se observaron mejoras de desempeño de hasta un 60% en la detección de encolamiento y un 85% en la disminución de falsos positivos al comparar el detector de Kullback-Leibler con aquellos basados en umbral.

En este sentido, estos resultados constituyen un avance importante en el aumento de la precisión y confiabilidad de detección de condiciones de fallas que justifica la incorporación de esta nueva estrategia en el ambiente de operaciones de una empresa de telecomunicaciones. Además, la hace eventualmente extensible a procesos controlados a través de colas.

# Dedicado

Dedicado a mi buen hijo Benjamín Milflen Torres Herrera, a quien adoro y es el mejor regalo de la vida.

# Agradecimientos

Mis sinceros agradecimientos a mi profesor guía Patricio Parada, por la oportunidad de enfrentar este desafío y su permanente motivación, e invaluable exigencia para lograr el presente trabajo.

También para el profesor Nicolás Beltrán a quién conozco desde mis tiempos de pregrado y ahora todo un honor seguir en contacto y contar con su participación en la comisión evaluadora.

Para mis padres Amada y Roberto, mis hermanos Flavio y Roberto.

Especialmente para mis Benja y Analia por su constante apoyo, afecto y comprensión con el tiempo que siempre es escaso.

En mi trabajo actual en Entel especialmente agradezco a G. Veas, N. Clavero, quienes siempre han tenido tiempo para conversar y colaborar con esta tesis.

A mis amigos de tesis del Magister y del laboratorio del departamento de ingeniería eléctrica, con quienes compartimos esta gran tarea del aprender.

Finalmente agradezco a mi amigo Mario Mancilla quien se fue de este espacio de vida a muy temprana edad, construyó una bonita familia con su esposa e hijos, emprendió su empresa y no tuvo el tiempo suficiente para seguir cumpliendo sus sueños; pero siempre tuvo tiempo para motivar a sus amigos.

Gracias al departamento de Ingeniería Eléctrica de la Universidad de Chile.

# Índice General

<b>Índice de Figuras</b>	<b>v</b>
<b>Índice de Tablas</b>	<b>vii</b>
<b>1 Introducción y antecedentes del problema</b>	<b>3</b>
1.1 Descripción del problema . . . . .	3
1.2 Motivación del trabajo . . . . .	4
1.3 Objetivos del trabajo . . . . .	5
1.4 Revisión de la literatura en problemas de detección . . . . .	6
1.5 Descripción del sistema de prepago . . . . .	8
1.5.1 Gestión de saldo de móviles prepago . . . . .	10
1.5.2 Gestión de tasación de móviles prepago . . . . .	10
1.5.2.1 Tasación por volumen de tráfico . . . . .	10
1.5.2.2 Tasación en línea red inteligente . . . . .	11
1.5.3 Ciclo de vida móviles prepago . . . . .	12
1.5.4 Cambio de estados . . . . .	14
1.5.5 Minuto de oro . . . . .	16
1.6 Problema encolamiento de cambios de estado . . . . .	17
1.6.1 Composición del encolamiento . . . . .	18
1.6.2 Impacto del encolamiento . . . . .	19
1.7 Flujo de gestión de solución de fallas . . . . .	20
1.8 Estrategia para abordar los objetivos . . . . .	22
1.8.1 Muestreo del proceso de encolamiento . . . . .	22
1.8.2 Análisis de datos . . . . .	23
1.8.3 Definición de condiciones de estado del proceso . . . . .	23
1.8.4 Representación de distribuciones de probabilidad . . . . .	24
1.8.5 Criterio de discriminación de condición de operación . . . . .	24
1.8.6 Parámetros del modelo de detección . . . . .	25
1.8.7 Criterio de eficiencia del detector . . . . .	26
<b>2 Marco teórico</b>	<b>28</b>
2.1 Series de tiempo . . . . .	28
2.1.1 Tipos de series de tiempo . . . . .	28
2.1.2 Objetivo del análisis de series de tiempo . . . . .	29

2.1.3	Métodos de descripción de series . . . . .	29
2.1.3.1	Tendencia . . . . .	30
2.1.3.2	Análisis de series con variación estacional . . . . .	31
2.1.3.3	Metodología de manejo de datos . . . . .	32
2.1.4	Procesos estocásticos . . . . .	33
2.2	Test de Hipótesis . . . . .	33
2.2.1	Errores del test de hipótesis . . . . .	34
2.2.1.1	Error tipo I y Error de tipo II . . . . .	34
2.3	Divergencia Kullback-Leibler . . . . .	35
2.4	Test de Hipótesis y divergencia de Kullback-Leibler . . . . .	36
2.5	Cadenas de Márkov . . . . .	40
2.5.1	Probabilidad de transición “K” pasos . . . . .	41
2.5.2	Probabilidades totales . . . . .	41
<b>3</b>	<b>Desarrollo e implementación de Detector Kullback-Leibler</b>	<b>42</b>
3.1	Análisis de serie de datos de encolamiento . . . . .	42
3.1.1	Muestreo de serie de datos . . . . .	42
3.1.2	Clasificación y manejo de series de datos . . . . .	44
3.1.2.1	Clasificación y evaluación de serie de datos . . . . .	44
3.1.2.2	Encolamientos periódicos conocidos . . . . .	45
3.1.2.3	Series de datos de condiciones de falla . . . . .	46
3.1.2.4	Series de datos de condición normal . . . . .	47
3.1.3	Representación de distribuciones para las condiciones normal y falla . . . . .	48
3.2	Implementación de detector de estado de fallas a través de Divergencia Kullback-Leibler . . . . .	50
3.2.1	Definición de valor de detección aplicando la divergencia Kullback-Leibler . . . . .	50
3.2.2	Detección de encolamientos con $Detector_{KL}$ . . . . .	50
3.3	Ajuste de parámetros del Detector Kullback-Leibler . . . . .	52
3.3.1	Parámetros del $Detector_{KL}$ . . . . .	52
3.3.2	Determinación de parámetros óptimos del detector . . . . .	52
<b>4</b>	<b>Estudio de desempeño de Detector Kullback-Leibler</b>	<b>55</b>
4.1	Generación de series de encolamiento . . . . .	55
4.2	Composición de la serie de prueba . . . . .	56
4.2.1	Elementos de la serie de prueba . . . . .	58
4.2.1.1	Generación de serie de puntos en condición normal . . . . .	58
4.2.1.2	Generación de serie de puntos de encolamiento . . . . .	58
4.2.1.3	Generación de serie de puntos de perturbación . . . . .	60
4.3	Estudio de desempeño $Detector_{KL}$ con series simuladas . . . . .	61
4.4	Criterios de desempeño $Detector_{KL}$ . . . . .	61
4.4.1	Criterios desempeño $D_{KL}$ para encolamientos . . . . .	62
4.4.2	Criterios desempeño $D_{KL}$ para perturbaciones . . . . .	62
4.5	Resultados de desempeño $Detector_{KL}$ . . . . .	63

<b>5</b>	<b>Conclusiones y Aportes del trabajo</b>	<b>69</b>
5.1	Conclusiones del trabajo . . . . .	69
5.1.1	Conclusiones globales . . . . .	69
5.1.2	Conclusiones por sección . . . . .	70
5.1.2.1	Conclusiones sobre requerimientos del trabajo . . . . .	70
5.1.2.2	Conclusiones sobre la construcción del <i>detector<sub>KL</sub></i> . . . . .	71
5.1.2.3	Conclusiones sobre desempeño del <i>detector<sub>KL</sub></i> . . . . .	71
5.2	Aportes del trabajo . . . . .	72
5.3	Potenciales extensiones del trabajo . . . . .	73
	<b>Bibliografía</b>	<b>74</b>

# Índice de Figuras

1.1	Porcentaje de distribución de móviles por segmento . . . . .	9
1.2	En el centro el mediador que recolecta todos los registros de tasación que ensambla y envía a la unidad de prepago para el descuento del crédito . . . . .	11
1.3	Comunicación entre la Central Telefónica (SSP) y el nodo de control de Servicio que consulta a la plataforma de prepago para confirmar si continúa la llamada . . . . .	12
1.4	Detalle del ciclo de vida de móvil prepago de acuerdo a su monto de saldo luego de cada llamada . . . . .	13
1.5	Diagrama de red simplificado de interacción entre la red móvil, la plataforma de prepago y el proceso de cambio de estado de móviles <i>prepago</i> . . . . .	15
1.6	Ejemplo del seguimiento del valor diario del Minuto de Oro Móviles <i>prepago</i> . . . . .	17
1.7	Evento de falla de encolamiento en proceso de cambios de estado para móviles <i>prepago</i> . . . . .	17
1.8	Detalle de la influencia de comando NETREQ en el volumen del encolamiento de comandos de <i>Cambios de estado</i> para móviles <i>prepago</i> . . . . .	18
1.9	Flujo de atención de gestión de solución de fallas. . . . .	21
1.10	Ejemplo de encolamientos producido por activación de móviles con crédito mensual. . . . .	23
1.11	Diagrama de modelo de detección de condición de operación del encolamiento. . . . .	25
2.1	Descomposición de series de datos . . . . .	30
2.2	Modelo de detector de condiciones de falla del proceso de cambio de estado. . . . .	39
3.1	Serie datos muestreada en el período de 14 meses, entre OCT de 2009 a DIC de 2010. . . . .	44
3.2	Encolamientos periódicos de cada primer día del mes, que se excluyen del estudio. . . . .	45
3.3	Serie de datos sin 01 día de cada mes, y esto origina un nuevo valor máximo para la serie de datos. . . . .	46
3.4	Encolamiento detectado y declarado como falla de encolamiento en el proceso de cambios de estado, 16 de Noviembre 2009. . . . .	47
3.5	Eventos de encolamiento concatenados en una serie de datos $Q(x)$ , dentro del período de observación. . . . .	47
3.6	Serie de datos de condición de operación normal del período de observación de 14 meses. . . . .	48
3.7	Distribución de probabilidad $P_1(x)$ . . . . .	49
3.8	Distribución de probabilidad $P_2(x)$ . . . . .	49



3.9	Resultado de detección de condición de falla de encolamiento cambio de estados a través del $Detector_{KL}$ . . . . .	51
3.10	Figura (a) barrido con Largo=27 con barrido de bins, (b) ejemplo de la detección de umbral y el valor de referencia de alarma. . . . .	53
4.1	Serie de prueba con encolamientos y perturbaciones generada con cadenas de Márkov, para el estudio de desempeño del $Detector_{KL}$ . . . . .	56
4.2	Matriz de estados de Márkov definida para generación de series de pruebas para calculo de desempeño. . . . .	57
4.3	Ejemplo de encolamiento con $fit$ 2.3 . . . . .	59
4.4	Ejemplo de encolamiento con $fit$ 1 . . . . .	60
4.5	Ejemplo de encolamiento con $fit$ 0.6 . . . . .	60
4.6	$Detector_{KL}$ se activa para encolamientos con magnitud inferior al umbral de alarma. . . . .	65
4.7	$Detector_{KL}$ se activa cercano a la posición de la alarma umbral (2000) y se mantiene hasta que finaliza la condición de falla. . . . .	66
4.8	$Detector_{KL}$ se activa en promedio 30 registros antes que la detección por el sistema de alarmas, para condiciones de encolamiento prolongados. . . . .	67

# Índice de Tablas

1.1	Tabla de parámetros OICK que definen la condición en el ciclo de vida del móvil prepago . . . . .	13
3.1	Parámetros óptimos largo de la muestra $Q(x)$ y número de bins $h$ . . . . .	53
4.1	Desempeño del detector para encolamientos de prueba . . . . .	63
4.2	Desempeño del detector para perturbaciones de prueba . . . . .	63
4.3	Desempeño del detector para encolamientos normales de prueba . . . . .	64
4.4	Desempeño del detector para encolamientos de prueba prolongados . . . . .	66
4.5	Desempeño del detector para perturbaciones de prueba . . . . .	68

## Organización de la Tesis

El presente trabajo tiene por objetivo principal introducir una nueva estrategia de detección de fallas en la operación de procesos y sistemas. Esta fue aplicada en el proceso de encolamiento de envío de comandos desde un sistema de gestión de prepago hacia los nodos de manejo de llamadas celulares en la red móvil. Este proceso aplica distintas acciones sobre los abonados de prepago de una red celular, siendo un proceso crítico y, por ende, la detección de fallas de encolamiento del proceso de forma temprana y certera mitigará el impacto producido por ellas.

En efecto, al implementar la estrategia de detección de condiciones de fallas por medio del detector basado en la divergencia de Kullback-Leibler se obtiene un mayor nivel de certeza en la detección, un menor índice de falsos positivos y una mejor respuesta ante perturbaciones esporádicas que presenta el comportamiento de series de datos del estudio. Este resultado representa un importante aporte, en cuanto se dispone de una nueva posibilidad para mantener la observación sobre procesos operacionales críticos, que comúnmente son observados sobre la base de monitoreo de alarmas que discriminan el valor presente con un valor asignado, ignorando la historia del proceso.

Por otro lado, se debe destacar que la implementación del sistema de detección basado en la divergencia de series de datos es de fácil implementación, y el nivel de procesamiento de los datos puede ser realizada en tiempo real. Para el caso del estudio se toma un período de muestra de "1" minuto, que corresponde a 60 muestras en una hora.

El presente trabajo se ha estructurado de la siguiente forma.

El capítulo 1 introduce la problemática y complejidad del sistema de gestión de prepago, indicando los ciclos de vida de los móviles prepago, la forma de realizar la tasación de estos móviles, el flujo de reserva de crédito, los procesos de recargas y tasación. Explica en forma detallada el flujo de estudio del proceso de cambios de estado de los móviles prepago y el impacto que genera en los clientes, como también para la empresa las fallas de encolamiento.

También en el capítulo 1 se presenta la revisión bibliográfica realizada considerando la búsqueda de estudios de detección de fallas sobre la base de medidas de divergencia, encontrando una mayor aplicación en estudios de reconocimiento de imágenes.

Además se destaca la motivación del estudio en función del alto impacto que representa las fallas en el proceso de operación de cambios de estado y se describe la estrategia de aplicación del modelo de detección por divergencia de Kullback-Leibler, definiendo las directrices para establecer su desempeño en comparación al sistema convencional de alarmas.

El capítulo 2 describe el marco teórico que se utilizó como apoyo para el desarrollo del trabajo, e introduce nociones de series de tiempo, test de hipótesis, divergencia de Kullback-Leibler y cadenas de Márkov.

El capítulo 3 presenta en detalle el desarrollo del estudio, desde la construcción del detector por divergencia de Kullback-Leibler (referido en el presente trabajo como  $Detector_{KL}$ ) para la detección de la condición de operación del proceso de cambios de estado de móviles prepago, definiendo los parámetros óptimos de construcción para el  $Detector_{KL}$  en base a las series de datos

de entrenamiento que fueron obtenidas en el período de observación.

El capítulo 4 contiene los resultados del estudio de desempeño del  $Detector_{KL}$  con series de prueba (simuladas) generadas con cadenas de Márkov y la aplicación sobre datos reales, obteniendo tablas de desempeño comparando los resultados de detección a través del  $Detector_{KL}$  versus el resultado de detección a través de alarmas, para los diferentes condiciones de estado, como encolamientos promedio, encolamientos prolongados y perturbaciones.

El capítulo 5 finalmente incluye los resultados y conclusiones más importantes obtenidas en la realización del presente trabajo, el aporte del estudio para el ámbito práctico y una visión de potenciales extensiones de este trabajo.

# Capítulo 1

## Introducción y antecedentes del problema

### 1.1 Descripción del problema

En el presente capítulo se describe la administración del proceso de cambio de estado mediante colas IPC (inter process communication), que almacenan de forma local cada instrucción, la que posteriormente es enviada hacia el nodo o elemento de red de destino (Comunicación cliente servidor vía TCP/IP). Estos comandos contienen las instrucciones que deben ser aplicadas sobre los perfiles de los abonados de red móvil. Por ejemplo, para activar la capacidad de realizar llamadas de voz cuando el móvil registra un saldo positivo de crédito o para bloquear la capacidad de realizar llamadas cuando el abonado registra un saldo inferior al mínimo permitido. Todos estos cambios de perfiles deben ser aplicados sobre el nodo de red móvil, que tiene la función de concentrar todos los perfiles de los abonados pertenecientes a una red móvil y se denomina HLR (Home local register) [1].

La gestión y control se realiza siempre sobre la base del saldo de dinero que mantiene el número móvil (o comercialmente llamado suscriptor prepago) en la plataforma de gestión de abonados prepago. En base a este crédito se activan las transiciones desde un estado a otro, por ejemplo, desde un estado sin saldo a otro estado con saldo positivo. Estos diferentes estados definen el “ciclo de vida” del móvil prepago. El control para el paso de un estado a otro se denomina “Cambio de estado”.

El perfil es una serie de parámetros que definen las capacidades que deben ser aplicadas al móvil cuando se encuentra activo sobre una red móvil: desde la capacidad de realizar o no realizar llamadas, hasta la calidad de servicio que será aplicada cuando el móvil realice una sesión de datos. Además el perfil contiene el método de tasación para las llamadas, el que puede ser *fuera de línea* generando un cobro al final de mes mediante una factura de cuenta telefónica como sucede para los clientes que mantienen un plan del tipo suscripción, o en *línea* para el caso de los móviles prepago que tienen un saldo inferior a un monto umbral, que en promedio es de 5 USD.

En régimen permanente, los nodos de una red móvil están en constante riesgo de presentar fallas [2] que interrumpen la operación continua. Evidentemente, aquellos procesos que son más

críticos generan un impacto mayor y en particular el proceso de cambios de estados de móviles prepago es el proceso con mayor criticidad en la operación continua de la plataforma de gestión de móviles prepago.

Bajo esta premisa la detección de los eventos de fallas de encolamientos juega un papel fundamental, ya que, al ser detectados en el menor tiempo de producido el evento es posible activar los procedimientos para corregir el problema y acortar el tiempo de duración de la falla, con ello reducir el tiempo de impacto para los clientes y para las empresas.

Además de la detección oportuna también existe la necesidad de realizar una detección confiable de los eventos de fallas de encolamiento, de esta forma evitar la pérdida de sensibilidad en las áreas que deben realizar tareas de supervisión y solución de problemas de operación de red.

## 1.2 Motivación del trabajo

La motivación de este trabajo es abordar el problema de detección de fallas de encolamiento para el proceso de “cambios de estado” de móviles prepago, motivado por el impacto que produce este tipo de fallas sobre los clientes y la organización (sección 1.6.2), incorporando una nueva herramienta de detección de fallas de encolamiento que represente un mayor desempeño en cuanto a la detección y falsos positivos, en comparación al sistema tradicional de alarmas de umbral.

En este trabajo se desarrolla esta nueva estrategia que permite detectar los eventos de falla de encolamiento en el proceso de *cambio de estado* (sección 1.5.4), la cual se basa en la divergencia Kullback-Leibler entre las distribuciones de los datos observados.

Dado que existe una serie de variables que intervienen en el proceso de control y gestión de móviles prepago (ver figura 1.5) la detección de fallas es compleja y en la actualidad los problemas derivados de la complejidad de la detección de estas fallas son:

- ⇒ El sistema de control y gestión de prepago tiene un número importante de variables de entrada, que son manejadas por otros sistemas que envían la información a la plataforma de prepago bajo condición normal de operación. Al momento de ocurrir un problema interno los sistemas de entrada continúan enviando datos que provocan un incremento de transacciones detenidas en la cola de procesamiento de cambios de estado.
- ⇒ Los sistemas que envían información hacia la plataforma de prepago no cuentan con un control de consistencia, por tanto, en cualquier minuto pueden enviar datos erróneos que provocan en la plataforma de prepago errores internos en el procesamiento. En este escenario ocurre una degradación de la capacidad de procesamiento que finalmente genera encolamientos y perturbaciones, las que al no superar los umbrales de las alarmas no son detectados hasta que en el sistema interno se produce el colapso y un incremento considerable del encolamiento.
- ⇒ Las causas del encolamiento pueden ser tan diversas que el tiempo de solución de la condición de falla puede volverse un factor relevante. El tiempo que la condición de falla

permanece presente representa un factor de amplificación (por aumento de encolamiento) del impacto sobre los clientes finales y se traduce en pérdidas para la empresa (véase sección 1.6.2).

- ⇒ Las alarmas discretas aparecen cada vez que se produce un valor superior al definido como umbral; esta condición representa una pérdida de sensibilidad sobre la operación del proceso, debido a la cantidad de falsos positivos que genera la alarma.
- ⇒ Los sistemas de control y gestión de prepago no cuentan con desarrollos internos para el monitoreo de la condición de estado de sus procesos. Esto obliga a los operadores a implementar otras herramientas de monitoreo que se basan en alarmas, que comparan valores observados con un umbral que es definido por la experiencia empírica.
- ⇒ En el inicio de la condición de falla se desconoce la causa del problema, por lo que el tiempo de solución será mayor.
- ⇒ Encontrar la causa de fondo del problema no es una tarea simple, y requiere un tiempo de análisis. La toma de acciones correctivas siempre estará sujeto al tiempo de detección de la condición de falla.

Todas estas dificultades sirven de motivación para implementar mejoras sobre el proceso de detección de condiciones de fallas en sistemas y procesos de misión crítica, incorporando un método de medida de la condición de operación del sistema a través del discriminante de Kullback-Leibler para determinar si el proceso se encuentra en una condición normal o una condición de falla de encolamiento.

En este sentido, lograr una detección oportuna y confiable representa un importante avance en los procesos de mitigación del impacto que producen los eventos de condición de fallas de encolamientos. Adicionalmente, contar con un sistema como el descrito nos permitirá:

- ⇒ Realizar una detección confiable, bajando considerablemente la tasa de falsos positivos que puede provocar una pérdida de foco en la atención del problema; ya que independiente de la complejidad del sistema, la detección se realiza en base a los datos observados a la salida del proceso.
- ⇒ Tomar acciones de corrección de forma segura sobre una mayor certeza de la presencia de una condición de falla real.
- ⇒ Fácil aplicabilidad en la detección, pudiendo ser un proceso en línea de rápida implementación.

### **1.3 Objetivos del trabajo**

El objetivo de este estudio es desarrollar un modelo de detección del inicio de condiciones de falla de encolamiento para el proceso de “cambios de estado” (sección 1.5.4), a través de la

utilización de la divergencia Kullback-Leibler como método de decisión del estado de operación del proceso, que logre un mejor desempeño en comparación al sistema de detección de fallas por activación de alarmas bajo condiciones de encolamientos normales, encolamientos prolongados y perturbaciones, que definen el comportamiento del encolamiento de “cambios de estado” de la plataforma que administra a móviles prepago.

Ello permitirá detectar el inicio de un encolamiento bajo condiciones reales de falla de una forma más confiable que el método de detección por alarma, que compara el valor del dato  $X(n)$  de encolamiento con un valor de umbral pre establecido. En el escenario actual la alarma solo toma en cuenta el valor de un instante en particular y no contiene la información del pasado de la variable aleatoria, produciendo alertas y falsos positivos que provocan pérdidas de sensibilidad. Esto es un problema recurrente de los sistemas de detección por alarmas, debido al ajuste empírico de los valores de umbrales para declarar una falla.

En procesos de misión crítica dado su importancia e impacto de las fallas es justificable incorporar nuevas técnicas más avanzadas para mejorar la representación de estos procesos y la detección de sus condiciones de operación.

Para lograr este objetivo se implementa el muestreo del encolamiento por un período prolongado de 14 meses para obtener un conjunto de datos lo suficientemente representativos de las dos condiciones contrapuestas del proceso, como son: (a) condición normal y (b) condición de falla de encolamiento. A partir de estos datos se obtienen los parámetros adecuados para generar un modelo de detección de condiciones de fallas de encolamiento que detecte eficientemente la transición entre ambos estados (condición normal a condición de falla) en base a la divergencia de Kullback Leibler entre la distribución de probabilidad observada de la muestra y las distribuciones de probabilidad conocidas de ambos estados de operación.

Finalmente, el modelo de detección debe ser estresado para obtener su eficiencia por sobre la detección por alarmas discretas. Para realizar esta parte del estudio se debe generar datos de encolamiento de pruebas similares a los reales para obtener el porcentaje de eficiencia y falsos positivos equivalentes con el sistema normal de alerta por alarmas de umbral.

## **1.4 Revisión de la literatura en problemas de detección**

La estrategia de resolución del problema de detección de una condición de falla del proceso de cambios de estado para móviles prepago consiste en tomar la serie de datos que representan el comportamiento del proceso y declarar la transición a una condición de falla utilizando un discriminante de medida de divergencia, que representa la distancia o diferencia entre dos distribuciones de probabilidad.

En este estudio el foco se concentra en determinar de una forma certera la transición del proceso desde un estado normal a una condición de falla, utilizando un modelo de detección que compara las funciones de masa de probabilidad resultante de la serie de datos de una muestra en tiempo real y las series de datos registradas durante el período de observación de 14 meses que caracterizan a las condiciones normales y de falla. Para finalmente discriminar la condición de operación del



proceso en tiempo real.

Las investigaciones que se han desarrollado sobre la base de estudios de las distribuciones empíricas de las series de datos, como por ejemplo, el estudio para determinar la exactitud de las funciones densidades de probabilidad [3] representa un acercamiento al estudio de distribuciones empíricas y la determinación de la veracidad de éstas introduciendo el concepto de divergencia. Otro estudio de detección correcta de las señales de barrido de un radar y una falsa alarma [4]; utiliza las distribuciones empíricas unida con medidas de distancia geométrica para mejorar la detección de señales en procesos no estacionarios.

En cuanto a trabajos de detección de fallas utilizando distribuciones empíricas, se encuentra el trabajo de detección de fallas en turbinas de viento [5] en donde el concepto de comparación entre distribuciones empíricas de las series de datos de valores de vientos para determinar sus diferencias (utilizando distribuciones de Weibull sobre los valores de las diferencias) y detectar fallas en las turbinas.

En el estudio de optimización de detección de fallas en sensores [6] se presenta una medida de divergencia denominada divergencia mutua para la optimización de la detección de las fallas sobre los sensores de medición por errores en la toma de datos, como es el caso de los sensores industriales que incluyen dentro del proceso de muestreo un elemento de ruido determinando el concepto de divergencia entre las densidades de probabilidad del ruido y la medición del sensor.

La divergencia de Kullback-Leibler se encuentra aplicada en procesamiento de imágenes, y en particular, en aplicaciones relacionadas con el reconocimiento de patrones. En este aspecto son variados los ejemplos de implementación en estimación de máxima verosimilitud [7] se plantea un método basado en un algoritmo de proximidad implementado con la divergencia de Kullback-Leibler entre las densidades posteriores de las series de datos y una función de penalización para obtener un mejor reconocimiento de imágenes en el campo de tomografías 3D.

En el caso de reconocimiento de imágenes en 2D también existen trabajos realizados en difusión estadística colector [8] que implementa la detección de la textura de los bordes de una imagen para determinar las regiones límites de una imagen, utilizando pequeñas muestras de las regiones observadas generando las distribuciones que finalmente se comparan a través de la divergencia de Kullback-Leibler.

La detección de objetos múltiples en una imagen también ha sido resuelta utilizando la divergencia de Kullback-Leibler para generar un método capaz de detectar automáticamente objetos que pertenecen a un mismo grupo de información de imagen tomando su estructura de información espectral [9]. Además, podemos encontrar la aplicación de divergencia de Kullback-Leibler para mejorar la capacidad de recuperación de imágenes de 65 a 77% tomando las distribuciones gauseana caracterizada por la energía contenida en la textura [10].

La divergencia de Kullback-Leibler se ha utilizado para mejorar la precisión de sensores de ubicación en función de verosimilitud espacial [11] donde el valor esperado puede ser representado como una distribución donde se propone como medida equivalente a la distancia de la divergencia de Kullback-Leibler entre dos funciones de distribución determinando su eficiencia a través de simulaciones.

También encontramos trabajos más enfocados en la detección temprana de fallas a través del procesamiento de las series de tiempo generadas por datos de muestra, por ejemplo, del valor de la presión utilizando las medidas del espectro de las series de datos en el estudio de diagnóstico temprano de presión regular de gas basado en el kernel de Kullback-Leibler [12].

En cuanto a la utilización de la divergencia de Kullback-Leibler para establecer la detección de condiciones de estado que cambian en el comportamiento de los datos de una variable aleatoria, se encuentra el estudio de detección y clasificación automática de estados de sueño multicanal [13]. El propósito de este trabajo es detectar de forma certera la actividad cerebral que representa un problema de actividad anormal en el paciente. El proceso es representado por un modelo ajustado de Multicanal autoregresivo (MAR) que finalmente genera un histograma, del cual se toma su función de probabilidad de masa la que se compara con los datos que va registrando el paciente, entregando en la salida los eventos en los que el paciente presenta desórdenes de actividad cerebral. Además presenta algunas interrogantes como el largo de las muestras que es un tema que se aborda en este trabajo para establecer el valor óptimo del largo de los datos de la historia del proceso observado.

Continuando con estudios de detección, el estudio de detección de variable auxiliar óptima basado en divergencia de Kullback-Leibler [14] se presenta como un trabajo más de análisis teórico que práctico, primero porque intenta abordar un problema recurrente en la detección como es la cantidad de falsos positivos que se puede generar en la detección. a través de la incorporación analítica de una variable auxiliar que pretende agregar certeza a la detección de una condición de falla.

Otra aproximación de trabajos relacionados con detección de fallas se encuentra en la inspección de asimetrías en piezas de ingeniería [15], que detecta anomalías en las cabezas de las piezas fabricadas mediante la obtención de serie de datos y con ello la distribución de probabilidad de las piezas bien formadas comparadas con las distribuciones de probabilidad de las piezas recién formadas.

En resumen podemos indicar que la divergencia de Kullback-Leibler ha sido ampliamente utilizada sobretodo en trabajos relacionados con procesamiento de imágenes 3D y 2D. También para mejorar la capacidad de recuperación de información desde fuentes que introducen errores y ruido en la toma de los datos. Además es posible afirmar que es incipiente la aplicación de esta técnica en la detección de fallas en procesos de operación en línea de transacciones de intercambio de información.

## 1.5 Descripción del sistema de prepago


La plataforma de prepago es un proceso de misión crítica que gestiona todo el conjunto de móviles prepago. Uno de los proveedores de soluciones de plataformas de gestión de móviles prepago es Orga Systems<sup>1</sup>, específicamente el nodo denominado OPSC por sus siglas en inglés

---

<sup>1</sup>Orga System empresa de origen germano que se dedica al desarrollo de soluciones de Control de Servicios (SCP) de llamados y tasación, en su línea de productos desarrolla la unidad OPSC Orga Prepaid System Center que es una

que hace referencia a “Orga Prepaid System Center” es el nodo de gestión de móviles prepago. La plataforma de gestión de móviles prepago administra los móviles según subdivisión asociada a la forma como se maneja el crédito de cada segmento.

1. **Móviles prepago:** Son todos aquellos móviles que deben realizar una compra de crédito equivalente en minutos; estos móviles sólo tienen la posibilidad de contar con un saldo positivo superior a un cierto valor para realizar llamadas.
2. **Móviles cuenta controlada:** Son todos aquellos móviles prepago que tienen un contrato facturado mensualmente. Cada primer día del mes se carga un monto de crédito equivalente a una cantidad de minutos y cuando estos minutos son consumidos el cliente tiene la posibilidad de realizar recargas de crédito para continuar realizando llamadas, hasta que nuevamente el siguiente primer día del mes se asigne el monto equivalente a los minutos del Plan mensual.
3. **Móviles del Tipo Empresas:** Son aquellos móviles que se asignan al uso de empresas. Cada empresa tiene una cantidad alta de crédito equivalente a minutos, donde a través de portales de administración personalizado cada empresa puede asignar un subconjunto de minutos a cada móvil en función a la necesidad de uso.
4. **Móviles suscripción:** Son aquellos móviles que no se encuentran controlados por la plataforma de gestión de prepago; estos móviles tienen un proceso de facturación independiente.



**Figura 1.1:** Porcentaje de distribución de móviles por segmento

La plataforma de prepago es una solución centralizada de administración de saldo para móviles prepago. A través de esta plataforma se gestiona fundamentalmente dos conjuntos de procesos: (a) Los procesos de gestión de saldo según plan seleccionado por el suscriptor de prepago, y (b) procesos de tasación de llamadas de voz y cualquier otro servicio consumido por el cliente prepago (como compra de ringtones, backtones, kbyte de navegación wap de internet, buzón de voz, etc.).

plataforma de administración y tasación para operadores de telefonía móvil.

### 1.5.1 Gestión de saldo de móviles prepago

Para las tareas de gestión de saldo podemos destacar las siguientes funcionalidades.

- ⇒ Manejo de recargas de saldo: a través de los distintos canales de recargas (Transbank, Sencillito, Servipag o desde integradores de transacciones como Redfacil, que permite transacciones desde dispositivos móviles y redes de supermercado) es posible adquirir un crédito que se traduce en cantidad de minutos, bolsas de sms y de datos para ser consumidos a través del dispositivo móvil y que se asignan como saldo contable al número móvil (MSISDN Mobile Subscriber ISDN Number).
- ⇒ Manejo de bonos mensuales: Es posible adquirir un bono que se activa mensualmente en los días que el abonado define por una cierta cantidad de meses o semanas, dependiendo de las ofertas que se van enviando por segmento de clientes, de esta forma paga un valor menor por un bono que se traduce a un paquete de minutos, como por ejemplo 200 SMS y tráfico ilimitado en días específicos del mes.
- ⇒ Manejo de planes y tarifas: Existen diversos planes comerciales a los que un abonado prepago puede suscribirse independiente del monto que mantenga, estos planes están orientados a segmentar el tráfico de minutos en base a horarios, por ejemplo plan nocturno para abonados de desean un mayor tráfico en ese horario.
- ⇒ Manejo de reservas de crédito: para asignaciones previas de saldo y transferencias de saldo desde un móvil a otro, o cargos de crédito a cuenta de otro móvil.

### 1.5.2 Gestión de tasación de móviles prepago

Todas las llamadas generadas por los móviles deben ser tasadas y, posteriormente, rebajar del monto de crédito asociado al número móvil en la plataforma de prepago. En el caso de los móviles prepago esta tasación puede ser realizada mediante dos métodos de tasación de red, según su perfil en la base de datos de perfiles de móviles en el nodo de red HLR.

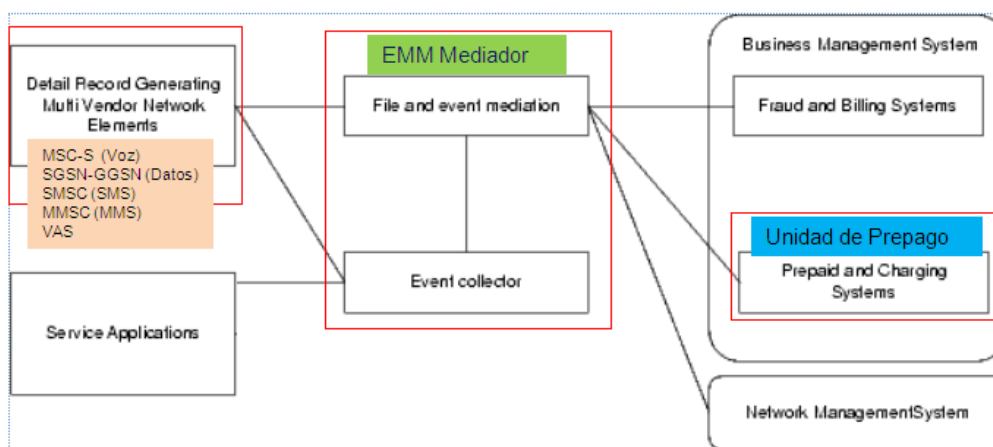
1. Tasación por volumen de tráfico.
2. Tasación en línea a través de red inteligente.

#### 1.5.2.1 Tasación por volumen de tráfico

Este método aplica para todas las llamadas generadas por móviles que tienen un parámetro para este tipo de tasación en la “base local de abonados de red HLR”. La modalidad de tasación por registros de la llamada se denomina tasación por volumen CDR [16] (Charging Data Record). Estos registros CDR son una colección de datos de la llamada, que contienen hora de inicio, tiempo transcurrido, número de destino de la llamada, identificador de la central telefónica, sector donde se inicia la llamada, etc. para la llamada en curso.

Una llamada puede generar varios registros CDR, los que son empaquetados por la central telefónica móvil en unidades de 300 kb, que son enviados hacia los nodos de tasación. Todos los CDR de una llamada por extensa que sea se les asigna un identificador único. Con esto se logra que los sistemas reconozcan todos los registros de una llamada para la correcta tasación.

El flujo se visualiza en la figura 1.2. Todos los registros de tasación (CDR) generados en las centrales telefónicas llegan hasta la unidad mediadora EMM [17] incluyendo los registros de tasación (CDR) de otros servicios tales como mensajes de texto (SMS), mensajes multimedia (MMS), acceso a datos para navegación a Internet. El mediador ensambla todos los registros para enviarlos a la plataforma de prepago para que se realice el descuento del crédito de acuerdo al valor del plan de cada móvil. Este proceso toma algunos minutos para que finalmente se produzca el descuento del saldo, de allí su condición tasación por volumen.




**Figura 1.2:** En el centro el mediador que recolecta todos los registros de tasación que ensambla y envía a la unidad de prepago para el descuento del crédito

### 1.5.2.2 Tasación en línea red inteligente

Si pensamos en el caso que un móvil mantiene un saldo muy cercano a cero y esta realizando una llamada, obviamente debido al tiempo de demora en el proceso de tasación por volumen (sección 1.5.2.1) el móvil registrará al término de la llamada un saldo negativo. Estos saldos negativos no se pueden cobrar o disminuir de la siguiente recarga del cliente y representan a todo evento una pérdida de ingresos para los operadores.

Para evitar este problema, se define un umbral de crédito en promedio \$ 5 USD, para que todos los móviles que se encuentren con un saldo inferior a este monto sean tasados a través de una comunicación en línea entre las centrales móviles y la plataforma de prepago para cada llamada generada por un móvil prepago.

En esta modalidad interviene un elemento de red llamado nodo de Punto de Control de Servicio SCP (Service Control Point) [18], que actúa como una interfaz de control entre la central telefónica de red móvil y la plataforma de gestión de móviles prepago (OPSC); figura 1.3.



**Figura 1.3:** Comunicación entre la Central Telefónica (SSP) y el nodo de control de Servicio que consulta a la plataforma de prepago para confirmar si continúa la llamada

Al iniciarse una llamada, la central interroga al nodo SCP utilizando protocolo de red Inteligente INAP <sup>2</sup>(Intelligent network application part) sobre transporte SS7 [19]; la central telefónica interroga a la unidad de control de servicio (SCP) para verificar si la llamada debe continuar. Este nodo de control de servicio SCP puede responder con una cantidad de tiempo en que debe continuar la llamada, por ejemplo 30 segundos o bien terminar la llamada en caso que el móvil no cuente con el crédito suficiente. Siendo el valor de 30 segundos la cota máxima de pérdida para cada móvil que se encuentre siendo tasado por este flujo, estableciendo de esta forma un método de tasación en línea cercano al tiempo real.

En este punto existe una pregunta razonable: **¿Si el método tasación por red inteligente presenta una solución para la tasación cercana en tiempo real, porque no se tasa todo tráfico de los móviles a través de esta modalidad?:**

La respuesta se basa en tres hechos:

- ⇒ Utilización de red inteligente que involucra una mayor capacidad de señalización desde las centrales de red móvil y el nodo de control de servicio SCP y una complejidad en el enrutamiento de la llamadas, lo que es prohibitivo en una red de comunicaciones real.
- ⇒ Existe un costo adicional de licencia que se debe cancelar al proveedor de la plataforma por el valor de llamadas simultaneas que ingresa a la red inteligente.
- ⇒ Este método es sensible a problemas de pérdidas de paquetes entre el nodo control de servicio SCP y la plataforma de gestión de prepago; estas pérdidas de datos se denominan "time out" y cuando una llamada es afectada por ello la llamada continúa sin control de cobro y puede continuar hasta que alguno de los dos interlocutores termine la llamada.

### 1.5.3 Ciclo de vida móviles prepago

El ciclo de vida de un móvil de prepago puede ser descrito mediante un grafo con diferentes estados. En cada uno de ellos se define un perfil particular dentro de la base de abonados de red HLR, que debe mantener su equivalente dentro de la base de datos de la plataforma de gestión de abonados prepago. Por ejemplo, si un móvil prepago no tiene saldo positivo en la base de

<sup>2</sup>INAP Estandar utilizado principalmente para llamadas de red inteligente para comunicar elementos de red de Servicio de Conmutación telefónico con el nodo de Control de servicio SCP, para control en línea de la llamada a través de consultas para continuar o liberar la llamada, Documentado en ETSI 300 374-1 y ITU-T Q.1228


datos de la plataforma de gestión de prepagos, debe existir el perfil equivalente con condición “inhabilitado” para realizar llamadas en la base de abonados de red HLR móvil.

El parámetro que se utiliza para definir el estado en el cual se encuentra el móvil es denominado OICK<sup>3</sup>; como muestra la figura 1.4 según el estado del móvil cambia el número del parámetro OICK. Con ello la “Central Telefónica Móvil” interpreta los distintos valores del parámetro OICK para determinar la forma de enrutamiento y tasación; mientras el móvil transita por los distintos umbrales de saldo.

En la tabla 1.1 se indican los distintos tipos de OICK y a continuación los diferentes estados dentro del ciclo de vida de un móvil prepagado:

**Tabla 1.1:** Tabla de parámetros OICK que definen la condición en el ciclo de vida del móvil prepagado

Valor OICK	Estado comercial del suscriptor
220	Prepago sobre el umbral IN
120	Prepago bajo el umbral IN
126	Prepago suspendido
150	Prepago bloqueado por robo
124	Prepago bloqueado por disociacion pack (EIR)
125	Cuenta Controlada, cortado a un N° IVR de callcenter
122	Pruebas IN ORGA
111	Móviles empresas
128	Prepago, idem 125



**Figura 1.4:** Detalle del ciclo de vida de móvil prepagado de acuerdo a su monto de saldo luego de cada llamada

<sup>3</sup>OICK Originating Intelligent network Category Key, es el parámetro que se asigna en el perfil del móvil dentro del HLR que define la forma de tasación y enrutamiento de la llamada dentro de una red móvil

1. **Instalado:** Es el estado inicial de todos los móviles prepago que se encuentran disponibles para la compra por el público en general. Este estado mantiene un perfil mínimo en el HLR que permite una vez encendido el móvil registrarse en la red y realizar una llamada a un IVR (Interactive voice response) que se comunica con la unidad de prepago para completar su activación y cargar el perfil a través de los comandos que la unidad de prepago envía hacia el nodo de abonados de red HLR, con lo que el móvil queda habilitado para realizar llamadas. Generalmente se asigna un crédito inicial en \$ pesos, de forma tal que el móvil pueda comenzar a realizar llamadas luego de recibir de parte del IVR la información sobre el número móvil que le fue asignado.
2. **Convertido:** Se define como un estado de transición desde que el móvil es desactivado y posteriormente es borrado con todo su historial luego de haber registrado un tiempo mayor a 6 meses sin tráfico (emitidas o recibidas). Estos 6 meses corresponden a una política implementada para reutilizar la numeración y quedan disponibles para ser asignados a un nuevo abonado móvil que inicia su ciclo de vida.
3. **Desactivo:** En este estado el valor del parámetro OICK es 126, que es equivalente desde el punto de vista de la red a la condición sin saldo, es decir “inactivo”. Desde el punto de vista de la unidad de prepago el móvil se encuentra sin la posibilidad de realizar una recarga de saldo, generalmente por políticas asociadas a tiempos de espera para borrado o a números que se encuentran extraviados. En los casos de robo el móvil queda asociado a un OICK 150 que al realizar una llamada es desviado a la plataforma de Call Center.
4. **Inactivo:** En este estado los móviles mantienen un saldo inferior a \$ 6 para realizar llamadas, por lo que la unidad de prepago envía los comandos para que estos móviles mantengan el valor del OICK en 126, con lo cuál solo puede recibir llamadas y realizar llamadas de emergencia o hacia el Call Center para atención comercial.
5. **Tasación IN:** En este estado la unidad de prepago indica que el móvil mantiene un saldo entre el umbral mínimo \$ 7 y máximo \$ 3600 para el método de Tasación por Red Inteligente (sección 1.5.2.2) para todos aquellos móviles que se encuentren en esta condición la unidad de prepago envía previamente los comandos para activar el parámetro OICK a un valor 120, con el cuál las centrales telefónicas interpretan este valor como una instrucción para activar la tasación a través de Red Inteligente.
6. **Tasación CDR:** En este estado la unidad de prepago indica que aquellos móviles que en su saldo cuentan con un crédito positivo superior al valor del umbral de \$3600 pesos se realizará la tasación a través de la generación de CDR (sección 1.5.2.1) para el conjunto de móviles en esta condición su parámetro OICK es de 220.

#### 1.5.4 Cambio de estados

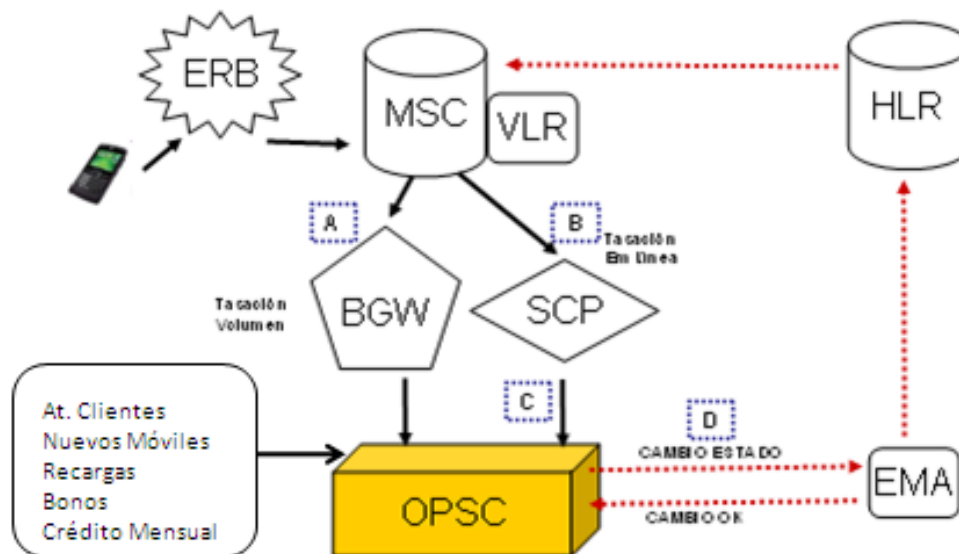
Los cambios de estado se generan cada vez que un móvil prepago transita por los umbrales de saldo definidos en su ciclo de vida (figura 1.4). Estas transiciones generan el envío de instrucciones



hacia la base de abonados HLR para modificación del perfil, en especial del parámetro OICK que define el método de tasación y corte de servicio.

Desde el punto de vista del cliente el cambio de estado de mayor importancia es el de activación de su móvil cuando el cliente realiza una recarga. Por el lado de la empresa y en función del aseguramiento de ingresos el estado de mayor importancia es el estado de inactivo (o corte), de forma de evitar que móviles sin saldo generen llamadas, pues en la siguiente recarga de crédito que realice el abonado no se descontará el saldo negativo. Dicha suma de minutos sin cobrar o de saldo de negativos de móviles prepago se denomina *minuto de oro* y constituye una pérdida para el operador.

Otro cambio importante es la activación inicial de móviles. Al comprar un nuevo kit de prepago y llamar al IVR el cliente debe escuchar el número asignado y luego debe quedar “activo” para realizar llamadas. Esto último requiere un alto índice de éxito en la activación inicial para generar un buen índice de conformidad del servicio por parte del cliente.



**Figura 1.5:** Diagrama de red simplificado de interacción entre la red móvil, la plataforma de prepago y el proceso de cambio de estado de móviles *prepago*.

Para realizar el cambio de estado la plataforma de gestión de abonados de prepago envía los comandos (figura 1.5) hacia el HLR a través de una unidad llamada EMA<sup>4</sup> (Ericsson Multi Activation), que envía estos comandos de modificación del parámetro OICK (tabla 1.1) hacia la base de abonados de red móvil HLR.

En el diagrama de la figura 1.5 muestra la interacción de la red móvil con la plataforma de gestión de prepago. Esta interacción tiene los siguientes alcances.

1. En el punto A: Cada vez que un móvil de prepago realiza una llamada se genera en la central

<sup>4</sup>EMA es una unidad de multiactivación, que interpreta los comandos en instrucciones que puedan ser entendidas por los elementos de red móvil

telefónica un registro con la información detallada de la misma, por ejemplo, número que realiza la llamada, número destino, hora, fecha, celda que cursa la llamada, etc. Toda esta información es enviada por la central hacia un nodo mediador (en la figura señalado como "BGW") que toma estos registros y los envía finalmente a la plataforma de gestión de prepago en donde se debe realizar el proceso de descuento del valor de la llamada. Este proceso es lento y toma en promedio 5 minutos en la llegada de los registros hasta la unidad de gestión de prepago (OPSC).

2. En el punto *B* y *C*: Presenta un flujo similar al anterior pero que se aplica para el conjunto de móviles que mantiene un valor de crédito bajo el valor definido por el operador, para generar el proceso de cobro muy cercano al tiempo real. Esto representa una solución al problema de desfase de tiempo del descuento mencionado en el punto "A", ya que el proceso de tasación se realiza siempre con un período menor o igual a 30 segundos (sección 1.5.2.2)
3. Además existe el bloque de *Atención Clientes* que envía hacia la plataforma de gestión de prepago la información relacionada con recargas de crédito, crédito mensual asignado, activación y habilitación de nuevos móviles prepago, borrado de móviles sin tráfico, cambio de planes desde suscrito a prepago, etc. También es el canal desde donde se obtiene la información de llamadas históricas, cuando un cliente solicita la información vía el portalweb o llamando a "Servicio a Cliente"
4. Finalmente toda la información de entrada a la plataforma de gestión de prepago es procesada en dicha plataforma, generando la decisión para realizar un *cambio de estado* que es aplicado sobre el perfil del móvil en la base de abonados de red HLR. Tales comandos son controlados por la cola de salida de comandos de cambios de estado en el punto *D* hacia el nodo de multi activación (EMA) que tiene la tarea de aplicar el cambio en el nodo de base de abonados de red HLR.

Nota: En los nodos de abonados de red móvil HLR existen entre 2.5 a 6 millones de móviles dependiendo de su capacidad límite por hardware, cada uno con su perfil individual. Estos nodos mantienen siempre la información del perfil del móvil, su ubicación y el estado de disponibilidad (disponible, ocupado, ausente, o apagado), independiente del lugar físico donde se encuentre el móvil, sea en la red local o en otra red realizando roaming.

### **1.5.5 Minuto de oro**

Existe una diferencia de tiempo entre el instante en que un móvil consume su crédito y el instante que se aplica en la red móvil el cambio de estado de "activo" a estado "inactivo" (o corte). A raíz de esta diferencia de tiempo se genera un saldo negativo en cada transición de los móviles de prepago que es cuantificada y monitoreada para efectos de aseguramiento de ingresos. Este concepto se conoce como *Minuto de Oro*.




Figura 1.6: Ejemplo del seguimiento del valor diario del Minuto de Oro Móviles *prepago*.

## 1.6 Problema encolamiento de cambios de estado

La plataforma de gestión de prepago controla el envío de comandos de cambios de estados (figura 1.4) para la actualización del perfil del móvil hacia el nodo de abonados de red HLR. El envío de estos comandos es controlado por un proceso de colas IPC (inter-process communication) del tipo FIFO<sup>5</sup> (First Input First Output). Dada las características de operación de la cola FIFO, si existe una falla que impida el envío de comandos (punto D en fig 1.5) hacia los elementos de red, los siguientes comandos comenzarán a ser encolados aumentando la cantidad de elementos dentro de la cola.

Para ilustrar estos eventos de encolamiento se presenta una figura caso real (figura 1.7), donde a causa de un problema interno de la plataforma de prepago baja el desempeño para el procesamiento de los comandos de la cola FIFO y la cantidad de requerimientos al interior de la cola comienza a crecer.




Figura 1.7: Evento de falla de encolamiento en proceso de cambios de estado para móviles *prepago*.


<sup>5</sup>FIFO sistema de manejo de colas sin prioridad donde la primera instrucción en ingresar a la cola es la primera instrucción en ser procesada y salir de ella.

### 1.6.1 Composición del encolamiento

El encolamiento está compuesto por distintos tipos de comandos que podemos clasificar en los siguientes tipos según su propósito:

- a Encolamiento NetReq.
- b Encolamiento Billing Record FIFO.
- c Encolamiento Colas ICR.
- d Encolamiento Billing Record IN.
- e Encolamiento Xact.
- f Encolamiento Pcollet.
- g Encolamiento OPDC.
- h Encolamiento Netrsp.

En la práctica se ha identificado que el encolamiento de mayor influencia en total de la cola FIFO 1.7 es la cola NetReq como se muestra en la figura 1.8.



**Figura 1.8:** Detalle de la influencia de comando NETREQ en el volumen del encolamiento de comandos de *Cambios de estado* para móviles *prepago*.

Los comandos del tipo “NetReq FIFO” son comandos que solicitan realizar los cambios de estado asociados a los parámetros OICK en el perfil de los abonadas en el HLR. Recordemos que las transiciones de estado dependen del saldo asociado al móvil y del estado inicial del móvil (sección 1.5.3). En particular las colas “NetReq FIFO” están relacionadas directamente a las transiciones entre los diferentes umbrales de saldo como se muestra en la figura 1.4; por lo tanto, un encolamiento generará retraso en la aplicación de estos cambios de estado, produciendo un impacto mayor que se detalla en la siguiente sección.

## 1.6.2 Impacto del encolamiento

Como se ha mencionado el proceso de cambio de estado es crítico, ya que representan el tipo de proceso de cobro (o descuento de crédito) para los móviles o la activación de un móvil cuando se realiza una recarga, y por lo tanto, es relevante para cada cliente.

Cuando se produce el encolamiento en el proceso de cambios de estado cualquier acción sobre el móvil queda detenida dentro de la cola y por lo tanto las transiciones del ciclo (sección 1.5.3) permanecerán detenidas por el intervalo de tiempo entre el inicio del encolamiento hasta la recuperación del proceso a la condición normal de operación.

A continuación se detalla el impacto del encolamiento del proceso de cambio de estado cuando se presenta una condición de falla (figura 1.7).

1. **Recarga de Saldo no Activada:** Bajo una condición de encolamiento, cuando un cliente que ha utilizado todo su saldo y se encuentra en la condición “inactivo” debe realizar una recarga de saldo para transitar al estado “activo”; con ello la unidad de prepago asigna el crédito y a través de la cola FIFO envía los comandos para activación del móvil en la base de abonados de red HLR. Al existir el encolamiento estos comandos quedan a la espera de ser enviados hacia la red, y para el cliente este es un problema mayor; ya que adquirió una recarga que no puede utilizar, ello genera un incremento de reclamos por este motivo en las áreas de atención a clientes.
2. **Corte de Móviles en estado Tasación por CDR:** Todas las llamadas de móviles que presentan un saldo superior a los \$ 3600 son tarifadas por registros CDR (sección 1.5.2.1) y ante un evento de encolamiento se producen los siguientes efectos.
  - ⇒ Si al finalizar una llamada el saldo restante es menor a \$ 3600 y mayor a \$ 6 la unidad de prepago debe enviar una solicitud de transición al estado de tasación por red inteligente, mediante la cual el descuento de saldo es realizado en línea, a través, del proceso descrito en la sección 1.5.2.2. En una situación de encolamiento dicha transición quedará pendiente en la cola de cambios de estados.
  - ⇒ Al finalizar la llamada si el saldo no cumple la condición anterior y es menor a \$ 6 pesos, la unidad de prepago debe realizar el cambio de estado al estado “inactivo” (inhabilitado para realizar llamadas), ya que su crédito es insuficiente. En un escenario de encolamiento de cambios de estado el comando de corte no será aplicado y permanecerá dentro de la cola hasta que el proceso retorne a su operación normal. Estos impactos tienen un efecto negativo desde el punto de vista del operador móvil, ya que bajo la condición de falla de encolamiento no es posible evitar que móviles sin el suficiente saldo puedan realizar llamadas. Ello se traduce en un incremento del minuto de oro (sección 1.5.5), que genera pérdida de ingresos para el operador.
3. **Activación de nuevos móviles prepago:** Todos aquellos kits de prepago que están disponibles para ser comprados, una vez adquiridos deben llamar a un número de acceso de plataforma IVR para completar su activación. En este proceso el IVR toma los datos de

la llamada y envía la información a la unidad de prepago para activar el crédito inicial de la compra (monto de crédito, bolsa de SMS, etc. que viene con la compra del Kit) y a su vez desde la plataforma de gestión de prepago enviar los comandos a través de la cola FIFO hacia la base de abonados de red HLR para agregar las capacidades al perfil (como activación SMS, activación de voz, datos, calidad de servicio de datos, desvío de llamadas, OICK, etc., es decir, la activación completa del perfil del móvil).

En el evento de falla de encolamientos este proceso de activación de nuevos móviles prepago quedará pendiente en la cola de envío de comandos, por el tiempo que permanezca presente la falla. Esto también genera reclamos en las áreas de atención a clientes, ya que el cliente no puede realizar llamadas a pesar de haber realizado la llamada al IVR para la activación de la línea telefónica móvil.

## 1.7 Flujo de gestión de solución de fallas

Todos los servicios que se encuentran en producción deben ser supervisados. En general, la supervisión del estado de operación de los servicios se determinan en base a los siguientes aspectos:

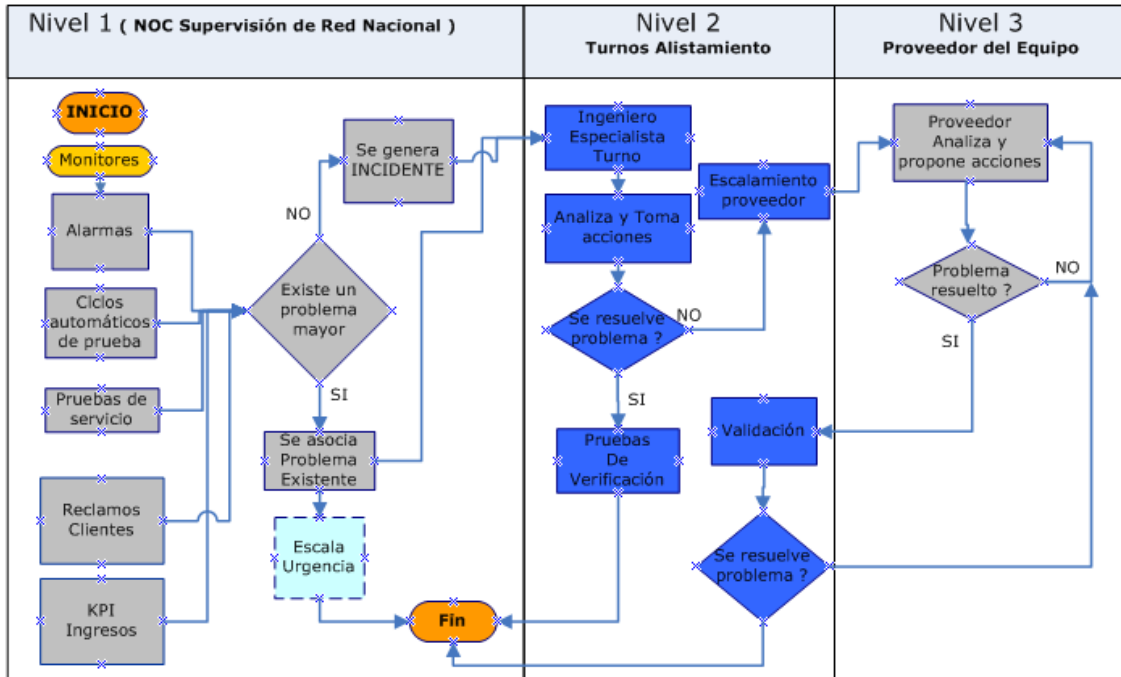
- ⇒ Alarmas de operación de equipos de la red, alarmas de procesos, alarmas de uptime, etc.
- ⇒ Anormalidad en los valores de KPI (Key performance Indicator) que presentan los servicios móviles (llamadas, sms, navegación, acceso a buzón de voz, etc.).
- ⇒ Baja de ingresos o desviación respecto de un día similar.
- ⇒ Errores en pruebas de robot que emulan a clientes utilizando servicios.
- ⇒ Pruebas cíclicas que se realizan por personal en terreno.
- ⇒ Ingreso de reclamos de clientes.

Una vez que se detecta el problema, en particular para fallas de encolamiento se produce una alerta por comparación del nivel de umbral (valor) de comandos en la cola FIFO de cambios de estado. Si el valor medido supera el valor de nivel de umbral (2000) se presenta la alerta de nivel crítico en los paneles de monitoreo en la unidad de supervisión centralizada que se denomina NOC <sup>6</sup> (por sus siglas en inglés Network Operation Center). En esta unidad el operador de turno toma la gestión del proceso de solución para encontrar el error [20] que produce la falla y realizando el siguiente flujo de escalamiento.

### 1. NIVEL 1: Aparición de la alerta de Encolamiento de Cola FIFO en unidad de Prepago.

---

<sup>6</sup>NOC es una área de operadores en turnos 7 días a la semana las 24 horas que están realizando tareas de supervisión del estado de la red móvil y de los servicios de valor agregado.



**Figura 1.9:** Flujo de atención de gestión de solución de fallas.

2. NIVEL 1: Operador de NOC toma conocimiento de la alarma y abre ticket de seguimiento interno.
3. NIVEL 1: Operador de NOC verifica si existen reportes de reclamos de clientes, u otras alarmas relacionadas con el servicio de prepago, y a las unidades que intervienen en el flujo de servicio (Figura 1.5)
4. NIVEL 1: Operador de NOC realiza escalamiento al turno de Ingeniero Administrador de Unidad de prepago solicitando revisar la situación de la alarma.
5. NIVEL 2: Ingeniero Administrador de turno evalúa la existencia de problemas asociados a procesos y/o degradación de las variables de desempeño de los servidores de la unidad de prepago, además verifica la cantidad de encolamiento y tendencia en aumento o disminución durante el tiempo transcurrido de la falla.
6. NIVEL 2: Ingeniero Administrador dependiendo de los resultados del aumento del encolamiento, realiza escalamiento al proveedor de la unidad de prepago reportando el incremento sorpresivo del encolamiento. En paralelo revisa estado de los nodos que intervienen dentro del flujo del proceso del cambio de estado (sección 1.5.4)
7. NIVEL 3: Proveedor realiza una conexión remota para verificar el comportamiento de la unidad y comienza el análisis de acuerdo a su protocolo interno de revisión de problemas, manteniendo el cumplimiento en el tiempo de respuesta y solución según los contratos de soporte vigente, documentados en un SLA [21] (Service Level Agreement).

8. NIVEL 3: Proveedor entrega feedback al Ingeniero Administrador respecto de la causa más probable del incremento del encolamiento de los comandos en la cola FIFO de la unidad de prepago, indicando las acciones que se deben realizar para solucionar dicho problema.
9. NIVEL 3: Ingeniero Administrador evalúa las acciones propuestas por el proveedor autoriza el plan de acción.
10. NIVEL 3: Una vez realizadas las acciones correctivas se realiza el seguimiento del descenso en los valores de encolamiento hasta que retornen a los niveles normales o promedios. Además se evalúan probables impactos en móviles que hayan quedado en alguna condición de error (generalmente móviles que no hayan quedado correctamente activados), regularizando inconsistencias o estimando compensaciones por ejemplo para aquellos móviles que durante el encolamiento hayan realizado recargas y por el problema de encolamiento su móvil no haya cambiado a la condición “activo” para realizar llamadas.
11. NIVEL 1: Finalmente vuelve la gestión al primer nivel para notificar la solución del problema, eliminando las contingencias y se documente las acciones realizadas durante el transcurso del problema, para que pasen a la base de conocimiento de solución de problemas.

## **1.8 Estrategia para abordar los objetivos**

Para lograr el objetivo 1.3 propuesto se define una estrategia para la definición e implementación de los distintos pasos para concretar el modelo de detección y posteriormente realizar el estudio de desempeño. En esta sección se describe los pasos de la estrategia realizados.

1. Muestreo del proceso de encolamiento
2. Análisis de datos
3. Definición de condiciones de estado del proceso
4. Representación de distribuciones de probabilidad
5. Criterio de discriminación de condición de operación
6. Parámetros del modelo de detección
7. Criterio de eficiencia del detector

### **1.8.1 Muestreo del proceso de encolamiento**


El muestreo del proceso aleatorio de encolamiento de comandos se realiza cada  $T = 5$  min. Tomando en cuenta que en eventos reales de encolamiento el crecimiento del tamaño de la cola es rápido se requiere realizar un muestreo con una mayor frecuencia. Por otro lado se busca la representación de las densidades de probabilidad para la caracterización del proceso; esto requiere



un largo de memoria suficiente para representar correctamente la densidad de probabilidad de la muestra. Según lo anterior se establece un período de  $T = 1$  min.

### 1.8.2 Análisis de datos

Análisis de series de datos obtenidos del proceso. Una vez obtenido los datos se debe realizar un pre procesamiento como remoción de valores extremos (denominados outliers); en general de aquellos valores que no representan una condición normal o de condición de fallas.



**Figura 1.10:** Ejemplo de encolamientos producido por activación de móviles con crédito mensual.

Por ejemplo en la figura 1.10 se visualiza un encolamiento mensual que se produce cada mes por la activación del crédito para los móviles de prepago en modalidad cuenta controlada. Estos eventos deben ser removidos de los datos ya que no son parte de la condición normal o la condición natural de falla.

### 1.8.3 Definición de condiciones de estado del proceso

Para el proceso de cambios de estado se definen sus condiciones de operación en base a la observación y definición del problema de estudio (sección 1.6), considerando los siguientes condiciones de estado del proceso.

- (A) **Condición Normal:** Se define como el estado en régimen permanente del proceso de cambio de estado, en donde los valores de encolamientos no presentan un crecimiento por sobre el lineal. Se incluyen perturbaciones o valores aislados y no consecutivos de encolamientos por más de 5 muestras.
- (B) **Condición de Falla:** Se define como la condición de aumento en el valor del tamaño de la cola de cambios de estado, se excluyen de este evento las observaciones del primer día de cada mes, dado que tal encolamiento se debe a la condición particular de activación de crédito mensual (detalles en la sección 3.1.2).

#### 1.8.4 Representación de distribuciones de probabilidad

Para las condiciones de operación del proceso de cambio de estado el objetivo es realizar la representación de las distribuciones de probabilidad. Se utiliza la representación de medida de probabilidad empírica tomando como fuente las dos series de datos que caracterizan el estado normal y el estado de encolamiento de fallas. Para obtener estas representaciones se realiza la contabilización de las frecuencias normalizadas de los valores de las series de datos. De esta forma se obtiene los histogramas normalizados que representan las probabilidades de masa de ambos estado de operación del encolamiento.

Estudiaremos las siguientes distribuciones empíricas:

$$P_1(x) \equiv \text{Distribución de probabilidad en condiciones normales} \quad (1.1)$$

$$P_2(x) \equiv \text{Distribución de probabilidad en condiciones de falla} \quad (1.2)$$

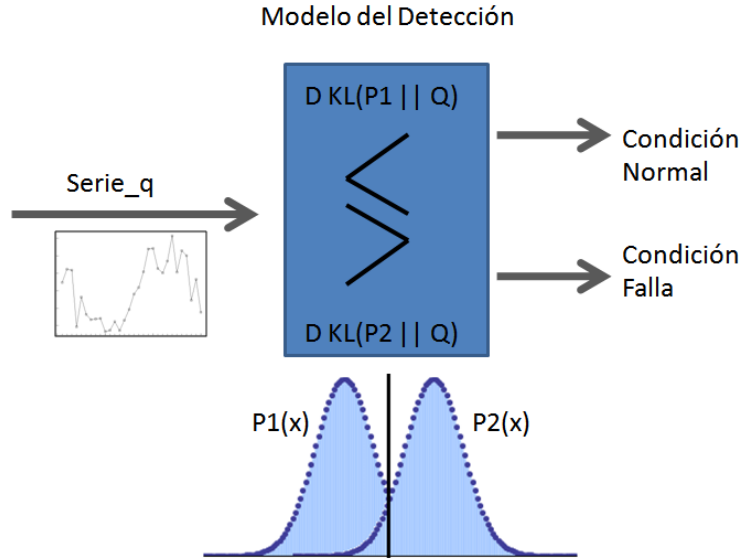
$$Q(x) \equiv \text{Distribución de probabilidad de la muestra} \quad (1.3)$$

#### 1.8.5 Criterio de discriminación de condición de operación

Para establecer el criterio de detección discriminante entre condiciones normales de operación y condiciones de falla se unen dos situaciones que deben ser resueltas.

- ⇒ Primero, la estrategia para toma de decisión. En este punto definimos el proceso de Test de Hipótesis " $H_1$  o  $H_2$ " para establecer si el proceso se encuentra en condiciones normales de operación  $H_1$  o en condiciones de fallas de encolamiento  $H_2$ , mencionando que se puede aseverar que el proceso se mantiene en condiciones normales la mayor parte del tiempo, consecuentemente con un proceso relacionado con un servicio de negocio de misión crítica.
- ⇒ El segundo paso es establecer el criterio de detección o de transición desde la  $H_1$  hacia  $H_2$ ; para ello se utiliza la medida de divergencia de Kullback-Leibler; que representa una medida de dissimilitudes entre dos distribuciones de probabilidad. Esta medida de divergencia no es acotada  $[0, \infty[$ , es decir, aumenta en la medida que las probabilidades a comparar se alejan o difieren (véase la divergencia de Kullback-Leibler 2.3). Específicamente, a partir de una muestra de datos de verificación de hipótesis " $datos_q$ " de largo acotado se representa su distribución comparando su similitud con las dos distribuciones empíricas construidas para los dos estados que consideramos como hipótesis ( $H_1$  Operación normal y  $H_2$  Operación en condición de falla) podemos establecer la condición de operación contenida en la muestra.

Aplicado este modelo de detección se obtendrá la definición de un estado resultante que finalmente se pueda comparar con las actuales alarmas de detección de fallas de encolamientos.



**Figura 1.11:** Diagrama de modelo de detección de condición de operación del encolamiento.

$$H_1 \equiv DKL(P_1 || Q) > DKL(P_2 || Q) \equiv \text{Condicion Normal} \quad (1.4)$$

$$H_2 \equiv DKL(P_1 || Q) < DKL(P_2 || Q) \equiv \text{Condicion Falla} \quad (1.5)$$

$$H_1 = H_2 \equiv \text{Umbral} \quad (1.6)$$

Siendo “ $Q$ ” la distribución empírica de la muestra de la serie datos que es comparada con las distribución de probabilidad  $P_1$  y  $P_2$  para determinar a través de su divergencia la condición de operación de la muestra de  $datos_q$ .

### 1.8.6 Parámetros del modelo de detección

El objetivo de esta sección es declarar el mecanismo para la definición de los parámetros de construcción del  $Detector_{KL}$ , proyectando los criterios utilizados posteriormente en la implementación del detector.

Para determinar los parámetros óptimos para la construcción del modelo de detección de condición de falla de encolamiento “*se define como criterio de sensibilidad detectar la falla de encolamiento en el valor actual del umbral detección del sistema de alarmas*”, que es el valor de 2000 instrucciones en la cola de cambio de estados (sección 1.5.4).

Definido el criterio de sensibilidad continua la definición de la(s) variable(s) que constituyen los parámetros de construcción del modelo de detección de fallas de encolamiento, y como se menciona en la sección 1.8.4 para determinar las transiciones de estado del proceso en estudio se necesita como primer paso establecer la representación de los datos. Para ello se necesita tomar en cuenta la resolución de la representación empírica de los datos (resolución de bins) y el largo de

la muestra de datos. Para obtener estos parámetros se define una estrategia de iteración de ajuste basado en el criterio de sensibilidad como patrón conocido de detección, utilizando el mecanismo siguiente.

1. Con el patrón o criterio de detección como objetivo de detección se realiza las iteraciones para determinar el largo de la muestra  $Ln$ . Por ejemplo el largo  $Ln$  no puede ser muy pequeña, ya que en el caso extremo de largo  $Ln = "0"$  no es posible representar empíricamente una función de probabilidad. En el otro extremo si el valor  $Ln$  es muy grande la sensibilidad del detector sería baja producto del gran número de muestras  $n$ , por el peso de la memoria que impediría conocer el estado actual del proceso. Las iteraciones se realizan desde una valor pequeño hasta un valor mayor al promedio observado de duración de los casos de encolamientos, que en la práctica alcanza 150 observaciones (cada observación equivale a un minuto).
2. Para establecer la cantidad de  $nbins$  de resolución necesaria para una mayor precisión en la detección al igual que en el caso del largo de la muestra de datos, se realizan iteraciones barriendo desde un valor pequeño de resolución de bins hasta el valor máximo de resolución, utilizando como cota máxima el valor promedio máximo observado de duración de encolamientos reales.

### 1.8.7 Criterio de eficiencia del detector

Para verificar la eficiencia del modelo de detección se establece como parámetro cuantitativo el "*Retraso de la detección*" entre una detección con el "sistema de alarma" y la detección a través del "*Detector<sub>KL</sub>*".

El retraso de la detección es la distancia entre el inicio del evento de encolamiento y la posición donde cada sistema de detección activa la condición de falla del proceso.

- a En el caso del sistema de detección de alarmas será la cantidad de posiciones desde que se inicia el evento de encolamiento hasta que la alarma se active cuando el valor de encolamiento supera el umbral definido (2000).
- b Para el caso de detección por *Detector<sub>KL</sub>* será la cantidad de posiciones desde el inicio del evento de encolamiento hasta la transición de la Hipótesis desde condiciones normales  $H_1$  hacia la condición de fallas de encolamiento  $H_2$ , que se logra una vez que el valor de salida del *Detector<sub>KL</sub>* cruce por el valor "cero" (veáse 3.2.1).

Además una vez establecido los criterios de eficiencia se define como estrategia evaluar y comparar el desempeño de ambos sistemas de detección, teniendo como foco el resultado del desempeño del *Detector<sub>KL</sub>* para obtener los resultados y conclusiones sobre el trabajo realizado, su aporte y proyección como herramienta de detección de cambios y fallas en la operación de procesos críticos. La estrategia de medición de este desempeño se estudia en el capítulo 4 sobre la base del comportamiento del *Detector<sub>KL</sub>* ante simulaciones de las condiciones que se evidencian en la serie de datos real, que son.

- a Eventos de perturbaciones.
- b Eventos de encolamientos normales.
- c Eventos de encolamientos prolongados.

# Capítulo 2

## Marco teórico

En este capítulo se presenta el contexto teórico para los tópicos que se aplican en el presente trabajo, desde el manejo de series de datos, prueba de hipótesis (test de hipótesis), divergencia de Kullback-Leibler y cadenas de Márkov.

### 2.1 Series de tiempo

El estudio de series de tiempo abarca distintas áreas de interés, como planeamiento económico, proyecciones de ventas, planeamiento de capacidad de red, riesgo financiero, medicina, ingeniería, economía, etc. Además se emplean distintas técnicas de tratamiento de datos para realizar la modelación y tomar acciones de predicción o control en base a los objetivos específicos de cada trabajo sobre series de datos.

Una serie de tiempo es un secuencia de observaciones de una variable en particular [22], donde cada observación está siendo registrada dentro de un tiempo específico. En el caso de las series de tiempo discretas estas observaciones son registradas a intervalos discretos, por ejemplo  $T_0 = [0, 1]$  (1 min para efectos del presente trabajo).

#### 2.1.1 Tipos de series de tiempo

Existen diferentes tipos de series de tiempo.

1. **Muestreadas:** Estas series son muestreadas desde una serie de medidas continuas que pueden ser registradas permanentemente por un período de tiempo (diario, horario, minutos). Corresponde a una discretización de series continuas.
2. **Agregadas:** series de tiempo agregadas o acumuladas, que contienen datos que por su naturaleza son agrupados, concatenados generando una serie que representa una condición global, manteniendo como requisito para la agrupación que los valores se registren en intervalos equivalentes.

3. **Discretas:** Una serie de registros consecutivos, a intervalos equivalentes de tiempo, como por ejemplo resultados financieros diarios, semanales, mensuales o anuales.

Para estas definiciones se mantiene la idea inicial, que son registradas en un período o intervalo de tiempo  $t$  equivalente.

### 2.1.2 Objetivo del análisis de series de tiempo

Los principales objetivos que se persiguen en el proceso de análisis de las series de tiempo es establecer las siguientes características:

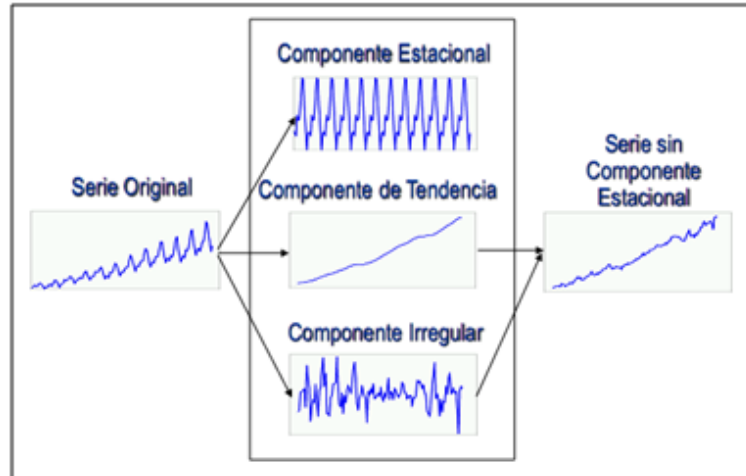
1. **Descripción:** Describir la serie de datos utilizando métodos de descripción estadísticos, gráficos, registrando sus valores representativos (max, min, tendencias, ciclos, etc).
2. **Modelamiento:** Definir modelos que representen el comportamiento de los datos. En este punto se tiene “Modelo Univariable” que son basados en modelos que consideran solo valores del pasado, mientras un “Modelo Multivariable” para una variable dada puede estar basada no solo en los valores pasados de esa variable, pero también en los valores presentes y pasado de otras variables. En el último caso la variación de en una serie puede ayudar a “describir” la variación en otras series. Por supuesto, todos los modelos son aproximaciones y su construcción es una arte como una ciencia.
3. **Predicción:** Determinar los valores futuros de una serie de datos manteniendo una representación muy cercana a la realidad, a partir de valores pasados y presentes.
4. **Control:** A partir de la caracterización de las series de datos es posible realizar acciones de control sobre los procesos, en el plano físico o económico. Los problemas de control están cercanamente relacionados con la predicción en muchas situaciones donde se requiera tomar acciones sobre un determinado proceso.

### 2.1.3 Métodos de descripción de series

Antes de comenzar a analizar las series de datos se debe “procesar” los datos con el fin de remover errores, por ejemplo en la obtención de datos por pérdida de respuesta de las consultas, o valores fuera de escala, etc. Dada estas posibilidades se debe revisar los datos y remover aquellos eventos que contengan falta de información o errores en el muestreo. En la literatura estas medidas son llamadas “outlier”. Un completo tratamiento de este se puede encontrar en “Box and Jenkins” sección 13.2.4 [23], y en “Chris Chatfield” sección 13.7.5 [22].

Las dos principales fuentes de variación [24] en series de tiempo son la “tendencia” y la “variación estacional”. Es útil presentar un breve resumen de descomposición de la variación de series de tiempo.

$$X_t = f(S_t, T_t, C_t, I_t) \quad (2.1)$$



**Figura 2.1:** Descomposición de series de datos

1. **Variación estacional ( $S_t$ ):** Esta variación es generalmente anual, mensual, semanal, cuando patrones similares de comportamiento surgen dentro de un período largo de tiempo, por ejemplo en el transcurso del año existe un mayor consumo de productos disponibles en determinadas estaciones.
2. **Tendencia ( $T_t$ ):** Este tipo de variación refleja un constante incremento o reducción de sus valores dentro de un período de tiempo; no se refiere a la definición matemática real sino a una observación en el período de muestra o un dentro de una variación estacional.
3. **Variación Cíclica ( $C_t$ ):** Incluye variaciones de los datos en períodos de mayor plazo; por ejemplo fenómenos de ciclos económicos de décadas, fenómenos naturales corrientes oceánicas, o comportamientos biológicos, etc.
4. **Fluctuaciones ( $I_t$ ):** Se utiliza a menudo para describir cualquier variación “remanete” después de remover la tendencia, estacionalidad y otros valores sistemáticos. Tales fluctuaciones pueden ser completamente aleatorias, en cuyo caso no es posible pronosticar, sin embargo, pueden exhibir pequeños términos de correlación.

### 2.1.3.1 Tendencia

Se refiere al movimiento ascendente o descendente que caracteriza un período de la serie de datos o toda su extensión. Así la tendencia refleja el crecimiento o declive en la serie de tiempo y puede representar una variedad de factores, tales como, una mejor estrategia de mercado, cambios en los consumidores, expansión de la empresa, factores de inflación que impulsan la venta en general, etc.

Utilizando un primer concepto para la tendencia como el “cambio a largo plazo en el nivel medio” y en términos sencillos es posible utilizar la definición [22] “Tendencia lineal + Ruido”, donde la observación en el tiempo “ $t$ ” queda representada por una variable aleatoria  $X_t$ .



$$X_t = \alpha + \beta t + \varepsilon_t \quad (2.2)$$

Donde  $\alpha$  y  $\beta$  son constantes y  $\varepsilon_t$  denotan el error media cero. El nivel medio en el tiempo  $t$  esta dado por  $m_t = (\alpha + \beta t)$  y se denomina *Tendencia* de la serie. La ecuación de tendencia 2.2 es una función determinística del tiempo, en algunos casos es llamada tendencia lineal *Global* [22].

En la práctica esto genera un modelo poco realista, por lo que hoy en día existe más énfasis en modelos que aceptan tendencias lineales *Locales* [22]. Por ejemplo una posibilidad es ajustar modelos donde la tendencia es localmente lineal con puntos de bajada y cambios abruptos que se interceptan, a menudo se aprecia con mayor sensibilidad en modelos que permiten una transición suave entre los diferentes submodelos. Bajo esta idea los parámetros de  $\alpha$  y  $\beta$  en la ecuación 2.2 evolucionan a través del tiempo. Esto podría hacerse en forma determinística, pero es más común asumir que  $\alpha$  y  $\beta$  evolucionan estocásticamente [22]. Otra posibilidad es que los datos presenten una condición *no lineal*, tal como una cuadrática en ascenso; en el caso de incrementos exponenciales estos son difíciles de manejar incluso si se utilizan logaritmos para transformar su tendencia a una forma lineal.

El análisis de series de tiempo que exhiben una tendencia depende de si se busca:

- (a) Medir la tendencia.
- (b) Remover la tendencia para analizar las fluctuaciones locales; esto también depende de si los datos presentan estacionalidad.

Con datos estacionales una buena decisión es comenzar con el calculo de los promedios anuales sucesivos, ya que estos proporcionan una descripción sencilla de la tendencia subyacente. Un enfoque de este tipo es adecuado, especialmente si la tendencia es bastante pequeña.

### 2.1.3.2 Análisis de series con variación estacional

La variación estacional generalmente aparece en períodos anuales, y puede ser *aditiva* si el incremento es constante año tras año o *multiplicativa*. Tres modelos comúnmente son empleados:

$$X_t = m_t + S_t + \varepsilon_t \quad (2.3)$$

$$X_t = m_t S_t + \varepsilon_t \quad (2.4)$$

$$X_t = m_t S_t \varepsilon_t \quad (2.5)$$

Donde  $m_t$  es la desestacionalidad de nivel medio en tiempo  $t$ ,  $S_t$  es el efecto estacionalidad en tiempo  $t$ , y  $\varepsilon_t$  es el error aleatorio.

El modelo 2.3 describe el caso *aditivo*; mientras que el modelo 2.4 y 2.5 involucran estacionalidad *multiplicativa*. En el modelo 2.5 el término de error también es *multiplicativo*, una transformación logarítmica cambiará esto a un modelo aditivo, el cual puede ser más fácil de manejar. Los índices estacionales  $S_t$  son usualmente asumidos para cambiar lentamente a través del tiempo, así que  $S_t \simeq S_{t-s}$  donde  $s$  es el número de observaciones por año.

En el análisis de series de tiempo que presentan variación estacional, depende de si se busca

- (a) Medir el efecto estacional.
- (b) Eliminar la estacionalidad.

Para la serie que presentan una pequeña tendencia, es usualmente adecuado estimar el efecto de la variación para un período en particular (Ejemplo Enero) para encontrar el promedio del mes menos el promedio anual para el caso “aditivo”, o la observación del promedio del mes dividido con el promedio anual en el caso “multiplicativo”.

### 2.1.3.3 Metodología de manejo de datos

Generalmente, se tiende a asumir que los datos han sido cuidadosamente reunidos sin datos fuera de escala (outliers) o sin valores perdidos desde la fuente de información. En la realidad ambos aspectos están presentes, por lo que una parte importante del trabajo de análisis se preocupa de examinar la calidad de los datos y prepararlos antes de ser procesados.

Una pregunta esencial es determinar si los valores medidos son apropiados para el desarrollo del problema. Para despejar esta pregunta se debe realizar el proceso de verificación de los datos, que a menudo se denomina “limpieza” o corrección de los datos, donde se identifica valores fuera de escala, se corrigen errores obvios, y se rellena cualquier observación perdida para mantener la periodicidad de las muestras. Todas estas anomalías en los registros contenidos en la serie de datos se les denomina “outliers” y es posible encontrar métodos sofisticados de tratamiento, que pueden ser revisados en las secciones 13.7.4 y 13.7.5 de [22].

Después de limpiar los datos, generalmente el siguiente paso para el analista de series de tiempo es determinar si la tendencia y estacionalidad están presentes en la serie. En ese caso ¿cómo tales efectos deben ser modelados, medidos o removidos?. A menudo esto es más importante que cualquier opción subsecuente con respecto al análisis y modelación de los datos de series de tiempo.

Una lista de posibles interrogantes que es recomendable despejar antes de continuar el modelamiento o tratamiento de las series de tiempo serán:

- ⇒ ¿Se entiende el contexto? ¿Se cuenta con las medidas de las “variables” correctas?
- ⇒ ¿Se registró la información subyacente de la(s) serie(s) en estudio?
- ⇒ ¿Existe algún valor perdido? ¿En ese caso, qué debe hacerse sobre ellos?

- ⇒ ¿Existe algún valor fuera de escala (outliers)? ¿En ese caso, qué debe hacerse sobre ellos?
- ⇒ ¿Existe alguna discontinuidad obvia en los datos? ¿En ese caso, qué debe hacerse?
- ⇒ ¿Tiene sentido transformar cualquiera de las variables?
- ⇒ ¿Presenta tendencia?
- ⇒ ¿Presenta estacionalidad?

#### 2.1.4 Procesos estocásticos

Si los valores futuros pueden ser pronosticados exactamente desde el pasado entonces la serie de datos es “determinística” (capítulo 2.4 [24]), sin embargo la mayoría de las series son aleatorias, el futuro solo es determinado por parte del pasado. Si se encuentra un modelo apropiado para un comportamiento aleatorio entonces el modelo debería ser un buen predictor.

Un modelo para series de tiempo estocásticas es llamado proceso estocástico y es denotado mediante  $(x_1, x_2, \dots)$  o generalmente  $\{X_t\}$ , una notación más precisa es  $\{X_t, t \in T\}$ , donde  $T$  denota el conjunto de índices donde el proceso esta definido.

En los procesos estacionarios las propiedades estadísticas subyacentes del modelo no cambian a través del tiempo. Formalmente, se dice que un proceso estocástico es estacionario de segundo orden si su primer y segundo momento es finito y no dependen del tiempo. El primer momento es la media  $E[X_t]$ , mientras que el segundo momento es la covarianza entre  $X_t$  y  $X_{t+k}$  para diferentes valores de  $t$  y  $k$ ; este tipo de covarianza es llamado autocovarianza y se denota por  $R_x(t;k)$ .

La varianza  $Var[X_t]$  es un caso especial de la autocovarianza cuando el ultimo retardo  $k$  es cero. De esta forma, un proceso es estacionario de segundo orden si  $E[X_t]$  es una constante finita  $\mu$  para todo  $t$ , si  $Var[X_t]$  es una constante finita  $\sigma^2$  para todo  $t$ , y si la función de autocovarianza depende solo del retardo  $k$ . Luego.

$$Cov[X_t, X_{t-k}] = E[(X_t - \mu)(X_{t-k} - \mu)] = \gamma_k \quad (2.6)$$

El conjunto de coeficientes de autocovarianza  $\gamma_k$  para  $t = 0, 1, 2, 3, \dots$  constituye la función de autocovarianza (acv.f) del proceso.

## 2.2 Test de Hipótesis

La ciencia plantea explicaciones tentativas o hipótesis acerca de fenómenos naturales, demostrando o refutando estas hipótesis a través de la investigación y pruebas. A nivel estadístico, se ha optado por este método científico mediante el desarrollo del método de inferencia llamada “Test de Hipótesis”, que a través de una muestra evalúa una afirmación hecha sobre un conjunto de valores o población.

La hipótesis estadística siempre involucra la evaluación de una afirmación hecha sobre la base de un valor de parámetros. Esta afirmación se manifiesta como un par de estados que son la hipótesis nula y la hipótesis alternativa.

Por ejemplo, en el test de hipótesis [25] Cap.7.2. se utiliza una muestra estadística para estimar los parámetros del conjunto de datos indicados en la hipótesis nula, por ejemplo para evaluar la hipótesis nula “el tiempo promedio para responder a los clientes por sus quejas es de 4 minutos durante un año” se debería utilizar el tiempo medio de la muestra para estimar el tiempo medio del conjunto. Si la estadística de la muestra no es la misma que para el conjunto, como casi nunca lo es, entonces si se rechaza la hipótesis nula implica decidir cuan diferente es la estadística de la muestra de la estadística del conjunto. Sin un procedimiento riguroso que incluya una clara definición operacional de una diferencia sería muy difícil decidir de forma consistente si una hipótesis es falsa o no. Los métodos de test de hipótesis proporcionan definiciones y permiten volver a plantear el proceso de toma de decisiones como la probabilidad de cálculo de una muestra dada.

En el caso de dos grupos el problema se puede expresar bajo ciertas condiciones para decidir entre las estadísticas de las muestras de cada grupo son respecto a la de los otros, lo que define la decisión de una de las hipótesis declaradas. **En particular, para este trabajo se toma esta opción como método de decisión entre dos condiciones representadas por una muestra de entrenamiento de cada condición de operación del proceso de estudio, que es comparada con una muestra nueva de validación para decidir por una de las dos hipótesis que representa la condición de estado; logrando de esta forma la detección de falla.**

$$\begin{aligned} H_1 & : Q(x) \sim P_1 \\ H_2 & : Q(x) \sim P_2 \end{aligned} \tag{2.7}$$

### 2.2.1 Errores del test de hipótesis

En la prueba de hipótesis siempre se enfrenta la posibilidad de favorecer erróneamente una hipótesis respecto de la otra, o también no rechazar apropiadamente la hipótesis falsa. Estas posibilidades se conocen como errores de tipo I y tipo II.

#### 2.2.1.1 Error tipo I y Error de tipo II

El error de tipo I ocurre si la hipótesis  $H_2$  es rechazada cuando ésta es verdadera y no debería ser rechazada. y se denomina “error de detección”.

El error de tipo II aparece si la hipótesis nula  $H_2$  no es rechazada cuando es falsa y debería ser rechazada. El riesgo o probabilidad de un error del tipo II es denotado por  $\beta$  y se denomina “Falso positivo”

En ambos casos se aplica la definición de las regiones de decisión para el test de hipótesis que se señala en la ecuación 2.7.

## 2.3 Divergencia Kullback-Leibler

Solomon Kullback y Richard Leibler [26] elaboraron una definición de la información contenida en un experimento para distinguir entre dos distribuciones hipotéticas en un espacio muestral. La definición original fue dada por Wiener en su “Cybernetics” [27] y es formalmente una generalización de la entropía Shannon, que está motivada por consideraciones de la teoría de comunicación y se justifica por el teorema de decodificación de canales; finalmente tiene que ver con las propiedades de información generalizada medida como una prueba de hipótesis estadísticas.

La entropía de una variable aleatoria es una medida de la incertidumbre que ella tiene [28], esto es, una medida de la cantidad de información requerida en promedio para describir la variable aleatoria. A su vez, la entropía relativa es una medida de la distancia entre dos distribuciones. La entropía relativa  $D(p \parallel q)$  es una medida de la ineficiencia de asumir que la distribución es  $q$  cuando la distribución verdadera es  $p$ . Por ejemplo, si se conociera la verdadera distribución de la variable aleatoria, entonces se podría construir un código con una longitud media de descripción  $H(p)$ . Si en lugar de eso se usa el código para una distribución  $q$ , implica que se necesitaría  $H(p) + D(p \parallel q)$  bits sobre el promedio para describir la variable aleatoria.

La entropía relativa o divergencia Kullback-Leibler entre dos funciones de probabilidad de masa  $p(x)$  y  $q(x)$  está definida por:

$$\begin{aligned} D(p \parallel q) &= \sum_{x \in X} p(x) \log \frac{p(x)}{q(x)} \\ &= E_p \left[ \log \frac{p(x)}{q(x)} \right] \end{aligned} \quad (2.8)$$

En estas ecuaciones se utiliza la convención  $0 \log \frac{0}{q} = 0$  y  $p \log \frac{p}{0} = \infty$ , la cual puede ser demostrada utilizando la regla de *Hôpital*.

La divergencia es siempre “no negativa” y es cero si y solo si  $p = q$ . Sin embargo, no es una verdadera distancia entre las distribuciones ya que no es simétrica ni satisface la desigualdad triangular. Sin embargo, a menudo es útil para pensar como una distancia entre distribuciones o entropía relativa.

Por otra parte, también es útil mencionar el concepto de información mutua, la cual es una medida de la cantidad de información que una variable aleatoria contiene sobre otra, es decir, es la reducción en la incertidumbre de una de las variables aleatorias debido al conocimiento de la otra. Se puede definir como dos variables aleatorias  $X$  y  $Y$  con una función de probabilidad de masa conjunta  $p(x,y)$  funciones de probabilidad de masa marginal  $p(x)$  y  $p(y)$ . La información mutua  $I(X,Y)$  es la entropía relativa entre la distribución conjunta y el producto de las distribuciones marginales  $p(x)p(y)$ .

$$\begin{aligned}
I(X;Y) &= \sum_{x,y} p(x,y) \log \frac{p(x,y)}{p(x)p(y)} \\
&= D(p(x,y) \parallel p(x)p(y)) \\
&= E_{p(x,y)} \log \frac{p(X,Y)}{p(X)p(Y)}
\end{aligned} \tag{2.9}$$

La relación entre la entropía y la información mutua se puede escribir como:

$$\begin{aligned}
I(X;Y) &= \sum_{x,y} p(x,y) \log \frac{p(x,y)}{p(x)p(y)} \\
&= \sum_{x,y} p(x,y) \log \frac{p(x|y)}{p(x)} \\
&= - \sum_{x,y} p(x,y) \log p(x) - \left( - \sum_{x,y} p(x,y) \log(x|y) \right) \\
&= H(X) - H(X|Y)
\end{aligned} \tag{2.10}$$

Así la información mutua  $I(X;Y)$  es la reducción de la incertidumbre de  $X$ , debido al conocimiento de  $Y$ . Por simetría también es correcto:

$$I(X;Y) = H(Y) - H(Y|X) \tag{2.11}$$

Por lo tanto,  $X$  dice tanto de  $Y$  como  $Y$  dice sobre  $X$ .

Dado que  $H(X;Y) = H(X) + H(Y|X)$  es posible redefinir la información mutua como:

$$I(X;Y) = H(X) + H(Y) - H(X,Y) \tag{2.12}$$

Finalmente se tiene:

$$I(X;X) = H(X) - H(X|X) = H(X) \tag{2.13}$$

Así la información mutua de una variable aleatoria con ella misma es la entropía de la variable aleatoria. Entonces esa es la razón que la entropía sea referida a veces como a su propia información o auto información.

## 2.4 Test de Hipótesis y divergencia de Kullback-Leibler

Con el objetivo de acercarnos al problema de detección a través de la decisión entre los estados de operación es que se definirá la decisión a través de una prueba de hipótesis general, donde las

medidas de divergencia se utilizarán como decisión para definir el estado de operación del proceso de cambios de estado de móviles prepago.

Consideramos la secuencia  $X_1 \dots X_n$  de variables aleatorias que se distribuyen de acuerdo a una distribución de probabilidad  $q(x)$ ; entonces consideramos las hipótesis respecto a las dos distribuciones de probabilidad “conocidas”.

$$\begin{aligned} H_1 & : Q(x) \sim P_1 \\ H_2 & : Q(x) \sim P_2 \end{aligned} \quad (2.14)$$

La regla de decisión:

$$g(X_1 \dots X_n) = \begin{cases} 1 & \equiv H_1 \text{ es verdadera cuando } Q(x) \sim P_1 \\ 2 & \equiv H_2 \text{ es verdadera cuando } Q(x) \sim P_2 \end{cases} \quad (2.15)$$

La ecuación 2.15 describe la salida del detector de Kullback-Leibler para todo el procesamiento de los datos, y el problema para establecer la prueba de hipótesis corresponde a encontrar la regla de decisión  $g(X_1 \dots X_n)$  óptima, tal que las siguientes definiciones sean minimizadas.

$$\begin{aligned} \alpha & = Pr \{g(X_1 \dots X_n) = 2 \mid H_1 \text{ es verdadera}\} \\ \beta & = Pr \{g(X_1 \dots X_n) = 1 \mid H_2 \text{ es verdadera}\} \end{aligned} \quad (2.16)$$

El lema de “Neyman Pearson” indica dos hechos; primero que  $\alpha$  y  $\beta$  no se pueden minimizar simultáneamente; ya que la reducción de uno implica el incremento del otro. El segundo hecho que la regla óptima que minimiza  $\alpha$  para  $\beta > \beta_0$  tiene forma:

$$\frac{P_1(X_1 \dots X_n)}{P_2(X_1 \dots X_n)} > T; \text{ para } T > 0 \quad (2.17)$$

Este número es llamado razón de verosimilitud, y establece una regla de decisión concreta basado en la muestra de  $X$  y la medida candidata  $P_1$  y  $P_2$ . A menudo se trabaja con el logaritmo de la razón de verosimilitud para simplificar la expresión en particular cuando es independiente idénticamente distribuida (i.i.d.).

El logaritmo de la razón de verosimilitud sobre la prueba de hipótesis estándar se define como:

$$L(X_1 \dots X_n) = \log \frac{P_1(X_1 \dots X_n)}{P_2(X_1 \dots X_n)} \quad (2.18)$$

En el caso particular que las muestras son del tipo i.i.d. el logaritmo de la razón de verosimilitud toma una forma familiar.

$$L(X_1 \dots X_n) = \sum_{i=1}^n \log \frac{P_1(X_i)}{P_2(X_j)} \quad (2.19)$$

Ahora la regla de decisión dada por la razón de verosimilitud es equivalente a:

$$D(P_{X^n} \parallel P_2) - D(P_{X^n} \parallel P_1) > \frac{1}{n} \log T \quad (2.20)$$

donde  $P_x^n$  es la medida de probabilidad empírica inducida por la muestra  $X^n = (X_1 \dots X_n)$ ; por lo tanto.

$$L(X_1 \dots X_n) = \sum_{j=1}^n n_j \log \frac{P_1(X_j)}{P_2(X_j)} \quad (2.21)$$

siendo  $n_j$  el número de veces que el valor  $x_j$  aparece en la muestra  $X^n$ . También se debe apreciar que:

$$n_j = nP_{X^n}(x_j) \quad (2.22)$$

donde  $P_{X^n}(x_j)$  es la medida de probabilidad empírica que el símbolo  $x_j$  aparece en la secuencia  $X^n$ ; entonces:

$$\begin{aligned} L(X_1 \dots X_n) &= \sum_{j=1}^J nP_{X^n}(x_j) \log \frac{p_1(x_j)}{P_2(x_j)} \\ L(X_1 \dots X_n) &= \sum_{j=1}^J nP_{X^n}(x_j) \log \frac{p_1(x_j)}{P_2(x_j)} \\ &= \sum_{j=1}^J nP_{X^n}(x_j) \log \frac{P_1(x_j) / P_{X^n}(x_j)}{P_2(x_j) / P_{X^n}(x_j)} \\ &= - \sum_{j=1}^J nP_{X^n}(x_j) \log \frac{P_{X^n}(x_j)}{P_1(x_j)} + \sum_{j=1}^J nP_{X^n}(x_j) \log \frac{P_{X^n}(x_j)}{P_2(x_j)} \\ &= n [D(P_{X^n} \parallel P_2) - D(P_{X^n} \parallel P_1)] \end{aligned} \quad (2.23)$$

Para esta ecuación se puede reemplazar  $L$  con la diferencia de la divergencia, por lo que la regla de decisión está representada:

$$\begin{aligned} D(P_{X^n} \parallel P_1) &\geq D(P_{X^n} \parallel P_2) & H_1 \text{ es verdadera} \\ D(P_{X^n} \parallel P_1) &< D(P_{X^n} \parallel P_2) & H_2 \text{ es verdadera} \end{aligned} \quad (2.24)$$

Finalmente, se implementa este criterio a través del calculo para el proceso de cambio de estados, con la finalidad práctica de identificar automáticamente en que condición se encuentra el proceso. Para lograr esto el prototipo a desarrollar, con sus parámetros y la lógica de programación que es implementada sobre Matlab se indica en la figura 2.2.



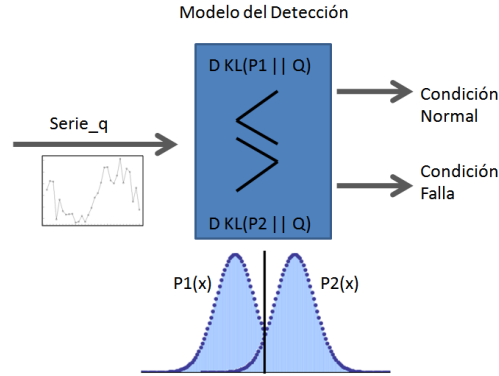


Figura 2.2: Modelo de detector de condiciones de falla del proceso de cambio de estado.

$$\begin{aligned} D(P_{X^n} \parallel P_1) &\geq D(P_{X^n} \parallel P_2) & H_1 \text{ es verdadera} \\ D(P_{X^n} \parallel P_1) &< D(P_{X^n} \parallel P_2) & H_2 \text{ es verdadera} \end{aligned} \quad (2.25)$$

- ⇒  $H_1$ : indica que el proceso de cambios de estado de prepagos se encuentra bajo condición normal o estable.
- ⇒  $H_2$ : indica que el proceso a entrado bajo una condición de falla.
- ⇒ En particular además se define el caso de Umbral en donde  $D(P_{X^n} \parallel P_1) \equiv D(P_{X^n} \parallel P_2)$  es equivalente.

En este punto es importante indicar que las distribuciones conocidas para este estudio representan el análisis del proceso por un período largo de tiempo en el cual se obtuvieron los datos cada un minuto del proceso de cambio de estado tomando el valor absoluto de encolamiento en cada minuto, por lo que:

- ⇒  $P_1(x_j)$  Corresponde a la implementación de una caracterización de la historia de condiciones normales del proceso analizado, tomando la serie de datos completa observada en el tiempo y generada su representación en función de la distribución de densidad de probabilidad empírica para el conjunto de valores contenidos en la serie sección.
- ⇒  $P_2(x_j)$  Corresponde a la implementación de una caracterización de condiciones de falla del proceso de cambios de estado registrado durante el período de observación, se establece la separación de estos datos para que generar su distribución de densidad de probabilidad de forma empírica.

El detector debe generar el procesamiento de cálculo de las divergencias Kullback-Leibler para generar una medida de divergencia que es analizada aplicando la hipótesis general para decidir sobre  $H_1$  ó  $H_2$  y por tanto, se declara la condición resultante.

## 2.5 Cadenas de Márkov

Una vez establecido el detector con sus parámetros de construcción como cantidad de números de bins para la representación de sus densidades de probabilidad y del largo de la muestra para obtener un reconocimiento de la condición de falla de forma apropiada y confiable (en base al entrenamiento con las series muestreadas a lo largo del período de observación), se necesita realizar pruebas de desempeño de detección comparado con los sistemas típicos de detección como son los sistemas de alarmas. Debido a que las series de datos observados se utilizan para la calibración del modelo es que se hace necesario generar series de datos para comprobar el desempeño. Para estos fines se utiliza las cadenas de Márkov.

Una cadena de Márkov es un tipo especial de proceso estocástico discreto en el que la probabilidad de que ocurra un evento depende del evento inmediatamente anterior. En efecto, las cadenas de este tipo tienen memoria “recuerda” el último evento y esto condiciona las posibilidades del siguiente evento. Esta dependencia del evento anterior distingue a las cadenas de Márkov de las series de eventos independientes.

Para cada cadena de Márkov se debe identificar:

- (a) Un espacio de datos.
- (b) Dados dos estados  $a_i$  y  $a_j$  se tiene que la denominada probabilidad de transición del estado  $i$  al estado  $j$ , que se define como  $p_{ij}$  y que designa la probabilidad de que el estado  $j$  suceda al estado  $i$ .
- (c) La matriz de transición del proceso, donde se ordenan todos las probabilidades de transición.

$$p = \begin{bmatrix} p_{11} & \cdot & p_{1m} \\ \cdot & \cdot & \cdot \\ p_{n1} & \cdot & p_{nm} \end{bmatrix}$$

$$\sum_{j=1}^n P_{ij} = 1; \forall i$$

$$p_{ij} \geq 0; \forall ij$$

- (d) El vector formado por las probabilidades del estado inicial del sistema, denominado “vector de probabilidad inicial”.

$$P^{(0)} = (P_1^{(0)}, P_2^{(0)}, \dots, P_n^{(0)})$$

$$\sum P_i^{(0)} = 1$$

$$P_i \geq 0; \forall i$$

### 2.5.1 Probabilidad de transición “K” pasos

La probabilidad de que un proceso pase desde el estado  $i$  al estado  $j$ , luego de  $k$  pasos se denomina probabilidad de transición en  $k$  pasos. La representamos por  $P_{ij}^k$ .

Las probabilidades de transición en  $k$  pasos pueden ser ordenadas en la matriz de transición en  $k$  pasos.

$$P^k = \begin{bmatrix} P_{11}^k & \dots & P_{1n}^k \\ \vdots & \ddots & \vdots \\ P_{n1}^k & \dots & P_{nn}^k \end{bmatrix} \quad (2.26)$$

Si  $P$  es la matriz transición de una cadena de Márkov, entonces la matriz de transición en  $k$  pasos es la  $k$  – esima potencia de  $P$ .

$$P^{(k)} = P^k \quad (2.27)$$

### 2.5.2 Probabilidades totales

La probabilidad que el proceso se encuentre en el estado  $a_i$  después de realizar  $k$  pasos, recibe el nombre de probabilidad total o absoluta, denotada como  $P_i^k$ .

A cada prueba  $K$  le corresponde un vector estocástico, formado por todas las probabilidades totales de esa prueba.

$$P^k = (P_1^{(0)}, \dots, P_n^{(0)}) \quad (2.28)$$

que recibe el nombre de “*distribución de probabilidad del paso k*”.

Ahora en una cadena de Márkov con matriz de transición  $P$ . dado el vector inicial de probabilidad inicial, se tiene:

$$P^{(0)} = (P_1^{(0)}, P_2^{(0)}, \dots, P_n^{(0)})$$

Tenemos que:

$$P^{(1)} = P^{(0)} P \quad (2.29)$$

$$P^{(2)} = P^{(1)} P = P^{(0)} P^2 \quad (2.30)$$

$$P^k = P^{(k-1)} = P^{(0)} P^k \quad (2.31)$$

## Capítulo 3

# Desarrollo e implementación de Detector Kullback-Leibler

Este capítulo se encuentra dividido en tres secciones que describe el trabajo realizado, en la primera sección (3.1.1) se detalla el trabajo realizado sobre los datos observados durante el período de 14 meses, clasificando el conjunto de datos y obteniendo subconjuntos de entrenamiento que representan las condiciones de operación del sistema, necesarios para la construcción del detector de falla de encolamiento a través de la divergencia de Kullback-Leibler.

En la sección 3.2 presenta la implementación y modelo de cálculo del  $Detector_{KL}$  para establecer la condición de operación de la muestra sujeta a evaluación, comprobando su operación de transición ante eventos de falla de encolamiento. Por último en la sección 3.3 se describe la implementación de los parámetros óptimos para el desempeño del  $Detector_{KL}$ , destacando la importancia que presentan estos parámetros para el desempeño final del  $Detector_{KL}$ .

### 3.1 Análisis de serie de datos de encolamiento

#### 3.1.1 Muestreo de serie de datos

En el inicio del presente trabajo las series de datos de encolamiento no se encontraban disponibles, dado que el sistema tradicional de alarmas no almacena el valor de los datos históricos, sólo compara el valor en cada muestra con el valor de umbral definido para activar la alerta, quedando una gráfica reducida que muestra un período acotado de tiempo, como se aprecia en la imagen 1.7 del primer capítulo.

Para obtener las series de datos con sus respectivos valores se realizó la construcción de un sistema de muestreo del comportamiento y evolución de los valores de encolamiento del proceso de cambios de estados (sección 1.5.4), a intervalos de  $T = 1$  minuto, almacenando cada valor en una base de datos por un período de 14 meses. Proceso que se implementó a través de los siguientes pasos.

- (a) **Construir un Servicio de consulta del valor de encolamiento en plataforma prepago:** Un servicio del tipo socket tcpip<sup>1</sup> en la plataforma prepago que exclusivamente responde por el valor numérico que presenta el encolamiento en el instante de la consulta.
- (b) **Período de muestreo del valor de encolamiento:** La debilidad de un sistema tradicional de alarmas es que obtiene los datos cada 5 minutos; esto se debe a la gran cantidad de equipos que debe monitorear y cada equipo o nodo de red contiene más de una variable. Por esta razón, se registra solo el evento de alerta cuando el valor obtenido de una variable sobrepasa el umbral definido, el resto de los valores no son almacenados, puesto que en el sistema tradicional de monitoreo de alarmas no cuenta con un propósito para los valores que no representan una alerta. Por ello no hay valores históricos de referencia y el ajuste del umbral se realiza en base a la experiencia en el tiempo.

En particular como se describió en el primer capítulo el encolamiento aumenta rápidamente y el período de 5 minutos no es suficiente para obtener los datos necesarios para desarrollar el objetivo (sección 1.3) de detección de la condición de encolamiento de cambios de estado.

Como parte del presente trabajo se ha implementado un sistema de consulta dedicado que utiliza una frecuencia de muestreo cinco veces mayor, logrando una resolución más fina en el muestreo de los datos, que permite lograr una mejor representación del comportamiento del encolamiento.

- (c) **Almacenamiento de los datos:** Una vez que ya se ha resuelto como obtener los datos y el aumento de la frecuencia de muestreo, los valores deben ser almacenados correctamente para registrar la evolución del encolamiento de cambios de estado. La opción recomendada es utilizar una base de datos por la gran cantidad de registros, bajo una estructura organizada de tablas por períodos de tiempo mensuales dentro de cada año, lo que hace posible un rápido acceso a los datos.
- (d) **Presentación de los datos:** Como menciona la sección 2.1.3.3 es importante la revisión de los datos antes de realizar la modelación u objetivos de fondo del estudio. En el caso del presente trabajo el volumen de datos obtenidos dentro del período de observación de 14 meses resultó una cantidad considerable (640.000 registros), que implicó la necesidad de implementar una herramienta de apoyo para lograr visualizar y procesar los datos de forma rápida; permitiendo la revisión de los datos desde períodos de tiempo amplios hasta reducidos (tilt-down) antes de abordar los pasos de construcción del detector.

Se recomienda utilizar RRDTool que es una herramienta de registro y visualización de datos especialmente orientada a grandes volúmenes, que cuenta con la posibilidad de agregar complementos que permiten realizar la revisión en línea de los datos con distintas resoluciones de intervalos de tiempo, fundamental para el proceso de “limpieza” de los datos.

---


<sup>1</sup>Es una interface normalizada de comunicación entre procesos servidor y cliente, en el servidor se activa un puerto específico donde el servicio atiende los requerimientos desde computadores clientes que solicitan datos por instrucciones de la capa superior.

### 3.1.2 Clasificación y manejo de series de datos

La serie de datos disponibles durante los 14 meses de observación contiene muestras que deben ser removidas antes de comenzar con la evaluación de los datos y el estudio del modelo de detección de fallas de encolamientos de cambios de estado. Este proceso se conoce como “manejo de los datos” o “limpieza de datos”, para este proceso algunos autores mencionan con especial énfasis el proceso de “manejo de los datos”, ya que, de existir errores en los datos de entrenamiento los resultados se verán afectados o no se logrará el objetivo deseado [22].

#### 3.1.2.1 Clasificación y evaluación de serie de datos

A continuación se indica el proceso de manejo o limpieza de los datos que se realiza en base a la motivación 1.2 y objetivos 1.3 definidos para el presente trabajo. Destacar que se busca la implementación práctica de un detector de condición de operación del estado del encolamiento de cambios de estado. En este punto toma especial foco la separación de las series de datos para la representación de sus funciones de distribución empíricas de cada estado de operación (Normal y en fallas).




**Figura 3.1:** Serie datos muestreada en el período de 14 meses, entre OCT de 2009 a DIC de 2010.

### 3.1.2.2 Encolamientos periódicos conocidos


Los datos periódicos conocidos se refieren a eventos de encolamiento que se producen cada primer día del mes, donde se aplica la recarga automática de crédito mensual para el conjunto de móviles cuenta controlada (véase sección 1.5), que equivale al 20% del total de móviles prepago (figura 1.1).

Aplicado el crédito se produce una activación masiva de todos los móviles que antes de este proceso se encontraban sin saldo suficiente para realizar llamadas. Esto genera el envío masivo de comandos produciendo un encolamiento de gran magnitud que se muestra en la figura 3.2. El encolamiento tarda horas de procesamiento, razón por la cual el proceso se realiza en horarios nocturnos de bajo tráfico, para no afectar a la operación normal y a los clientes durante el horario diurno.



**Figura 3.2:** Encolamientos periódicos de cada primer día del mes, que se excluyen del estudio.

**Justificación:** El evento del primer día de cada mes es una condición particular y no es considerado como parte de algunas de las dos condiciones que describen el proceso de “cambios de estado”, razón por la cual antes de continuar el procesamiento de los datos se excluye estos eventos de la serie total.



**Figura 3.3:** Serie de datos sin 01 día de cada mes, y esto origina un nuevo valor máximo para la serie de datos.

### 3.1.2.3 Series de datos de condiciones de falla


Las series clasificadas como eventos de condición de falla se generan a partir de la serie de datos original (figura 3.1) extrayendo los datos de aquellos eventos donde se declaró una condición de falla, de esta forma se obtiene la serie de entrenamiento de condiciones de fallas. Con ello se genera la distribución de probabilidad en condición de falla  $P_2(x)$  (ecuación 1.2).

**Justificación:** Los eventos definidos como condiciones de falla, son aquellos eventos que durante el período de observación fueron declarados como una falla, provocando los impactos mencionados en la sección 1.6.2 y que fueron notificados como un incidente al interior de la empresa, y para el cuál se aplicó el flujo de atención de fallas detallado en la sección 1.7.

*A continuación un extracto de una notificación de falla real, que da cuenta de la generación del encolamiento en la figura 3.4.*


**Unidad de Supervision de Servicios:** Encolamiento en Plataforma de Preago: El día 16/11/2009 a partir de las 20:40 hrs. aproximadamente se detecta encolamiento colas BillingRecordFIFO (transacción para tasación) y transacciones NetReqFIFO (transacciones hacia HLR, correspondientes a cambio de estado de móviles). Se realiza escalamiento con soporte del proveedor quienes proceden a verificar plataforma.





**Figura 3.4:** Encolamiento detectado y declarado como falla de encolamiento en el proceso de cambios de estado, 16 de Noviembre 2009.


Finalmente las series de fallas se concatenan, y a partir de estas series se construye la distribución de probabilidad  $P_2(x)$  (ecuación 1.2).



**Figura 3.5:** Eventos de encolamiento concatenados en una serie de datos  $Q(x)$ , dentro del período de observación.

### 3.1.2.4 Series de datos de condición normal

La serie de datos en condición normal es el resultado del procesamiento de la serie de datos sin primeros días de cada mes (figura 3.3) excluyendo además los datos de aquellos eventos donde aconteció una falla de encolamiento real, esta serie resultante es utilizada como serie de entrenamiento para condiciones normales 3.6, y de la cual se obtiene la distribución de probabilidad que define de la condición normal  $P_1(x)$  (ecuación 1.1).



**Figura 3.6:** Serie de datos de condición de operación normal del período de observación de 14 meses.

### 3.1.3 Representación de distribuciones para las condiciones normal y falla

Una vez obtenidas las series de datos que representan ambas condiciones (normal y falla) del proceso de cambios de estado, se requiere establecer una representación de la distribución de masa de probabilidad. Para lograr esta representación se realiza el procedimiento de representación empírica de las distribuciones de probabilidad. El histograma es un método utilizado para representar los datos y su forma de distribución de la misma forma que la función de masa muestra las probabilidades.

El rango de los valores de los datos es dividido en intervalos llamados “bins” y se gráfica la cantidad o proporción de observaciones que caen dentro de cada intervalo  $(Z_{i-1}, Z_i)$ , con  $i = 1, 2, 3, \dots, L(\text{bins})$ . La “función de masa de probabilidad” empírica para una variable aleatoria discreta esta dada por ecuación 3.1.

$$p_i = \frac{1}{N} \sum_{j=1}^N \mathbb{I}_{\{i\}}(X_j) \quad (3.1)$$

Donde la función indicatriz  $\mathbb{I}_i = 1$ , cuando el dato pertenece al bins  $i$ -esimo; en el intervalo  $\forall i \in \{1, 2, \dots, L\}$ .

En las figuras 3.7 y 3.8, se ha generado la distribución de las series que caracterizan las dos

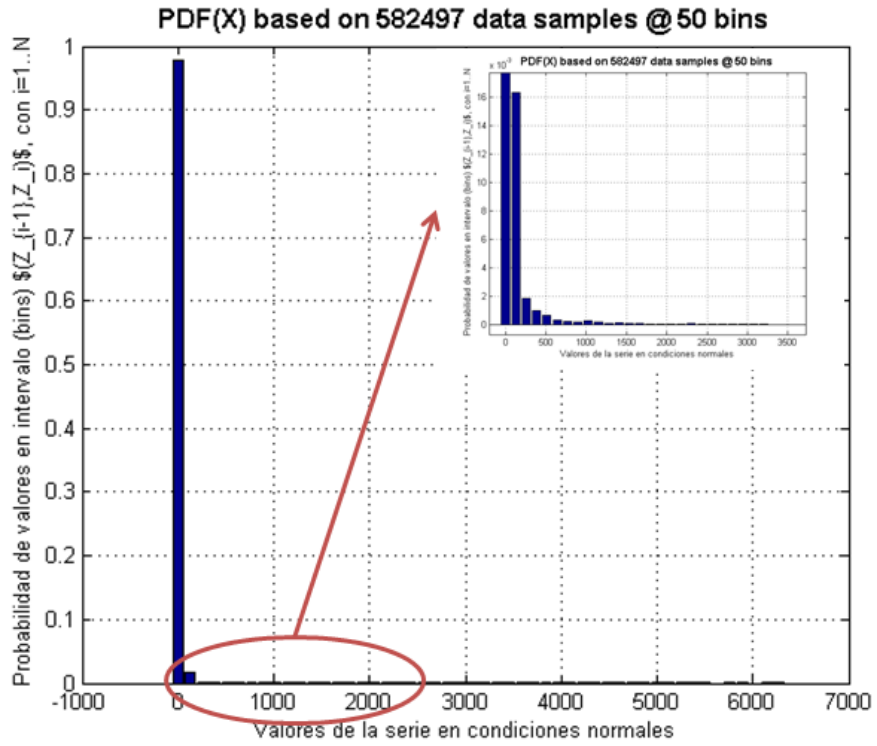


Figura 3.7: Distribución de probabilidad  $P_1(x)$

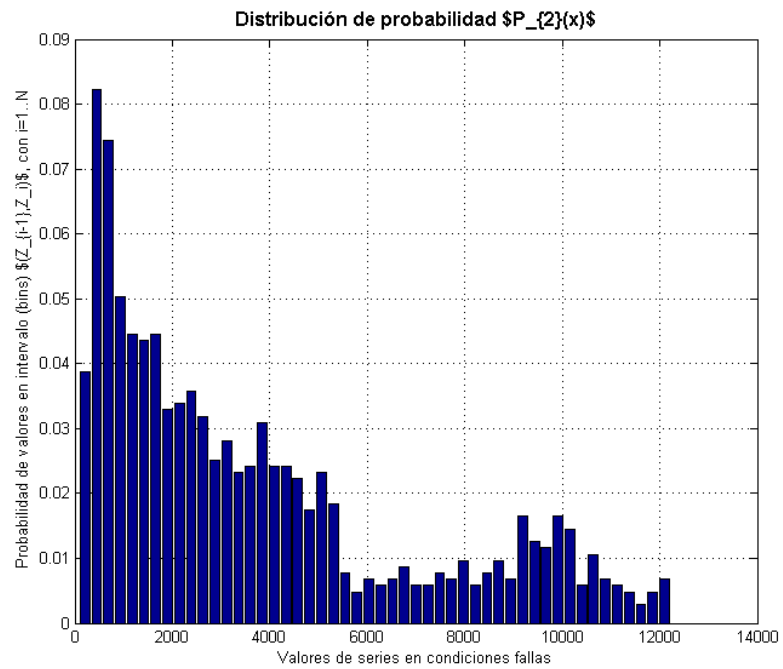


Figura 3.8: Distribución de probabilidad  $P_2(x)$

condiciones del proceso de cambios de estado. En la representación no está ajustado el valor óptimo de la cantidad de intervalos (bins) para el modelo del detector, este punto es definido como parte de la sección de “Parámetros del detector de encolamientos” (sección 3.3.1).

## 3.2 Implementación de detector de estado de fallas a través de Divergencia Kullback-Leibler

### 3.2.1 Definición de valor de detección aplicando la divergencia Kullback-Leibler

Como ya se tiene las distribuciones de  $P_1(x)$  y  $P_2(x)$  (sección 3.1.3), entonces al tomar una nueva muestra de datos  $Q(x)$  es posible entonces realizar el cálculo de las hipótesis planteadas como detección.

Para establecer el momento de activación del  $Detector_{kl}$  se define la condición en donde la diferencia entre la divergencia de  $P_1(x)$  sobre  $Q(x)$  y la divergencia de  $P_2(x)$  sobre  $Q(x)$  es igual a “cero”, que es el instante de transición del detector logrando el objetivo propuesto (sección 1.3) del presente estudio, y queda definido por la ecuación 3.2.

$$Detector_{KL} = [D_{kl1}(p_1(x) \parallel q(x)) = D_{kl2}(p_2(x) \parallel q(x))] = 0 \quad (3.2)$$

Además en régimen permanente el proceso se mantiene en el estado de *Condición Normal* manteniéndose “verdadera” la opción  $H_1$ , en la ecuación 3.3.

$$Condición Operación Normal \equiv H_1 : D_{kl1}(p_1(x) \parallel q(x)) > D_{kl2}(p_2(x) \parallel q(x)) \quad (3.3)$$

Cuando se alcanza el valor umbral en la ecuación 3.2, es el instante donde el proceso pasa a la *Condición de falla* convirtiéndose en “verdadera” la  $H_2$ , en la ecuación 3.4.

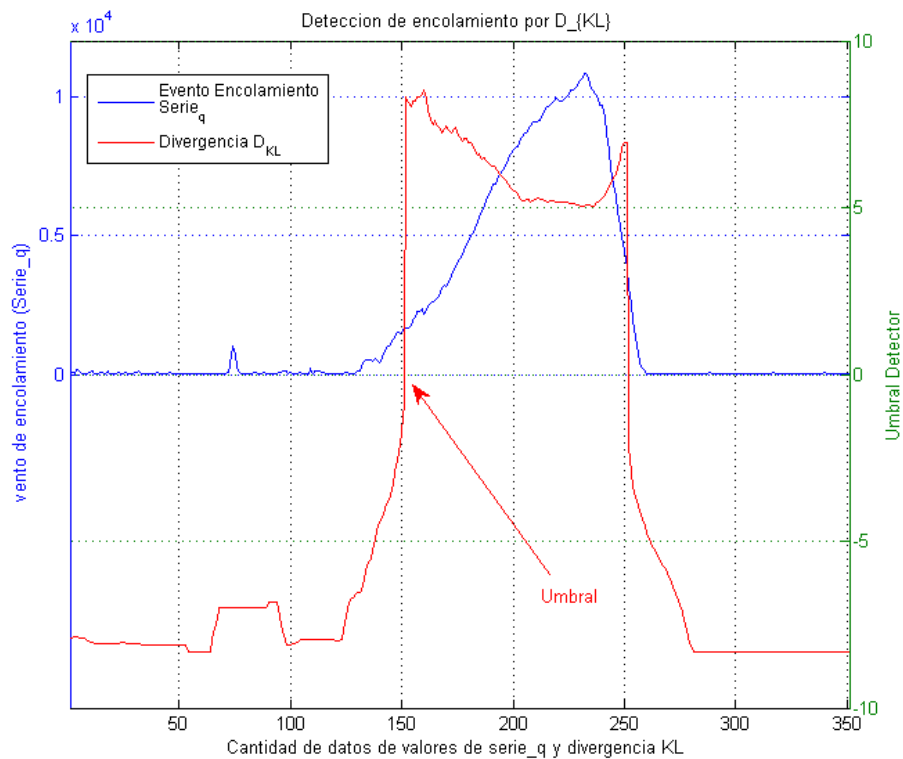
$$Condición Operación Falla \equiv H_2 : D_{kl1}(p_1(x) \parallel q(x)) < D_{kl2}(p_2(x) \parallel q(x)) \quad (3.4)$$

### 3.2.2 Detección de encolamientos con $Detector_{KL}$

Al utilizar una serie de prueba de una falla de encolamiento  $Q(x)$  y realizar la prueba de hipótesis podemos apreciar en la figura 3.9, que el detector de divergencia de Kullback-Leibler (ecuación 3.2) inicialmente presenta valores negativos durante el período donde los valores de la serie  $Q(x)$  presenta valores en condiciones normales.

En el resultado de detección del  $Detector_{KL}$  reflejado en la figura 3.9 se aprecia.

⇒ El  $Detector_{KL}$  bajo condición normal reporta valores negativos, correctamente como lo esperado, ya que la magnitud de la diferencia entre la serie de pruebas ( $datos_q$ ) es mayor



**Figura 3.9:** Resultado de detección de condición de falla de encolamiento cambio de estados a través del  $Detector_{KL}$ .

con respecto de la representación de condición de falla, por lo tanto se cumple la ecuación 3.3.

- ⇒ Durante el período de la falla de encolamiento el  $Detector_{KL}$  presenta valores positivos, confirmando que la diferencia de la muestra de ( $datos_q$ ) es mayor ahora con la condición de operación normal, por lo tanto su valor se mantiene positivo como plantea la ecuación 3.4.
- ⇒ La activación del  $Detector_{KL}$  se produce con la transición del valor resultante de la divergencia de Kullback-Leibler, y específicamente el detector toma el valor cero, como se señala en la definición de cálculo del  $Detector_{KL}$  en la ecuación 3.2.
- ⇒ El  $Detector_{KL}$  permanece en valores positivos hasta que el proceso de operación retorna a su condición de operación normal.

Hasta aquí no se ha precisado los valores de los parámetros del “detector de falla de encolamientos”. Estos parámetros son: (a) el largo de la muestra y (b) la cantidad de intervalos (bins) de representación de las distribuciones para conseguir una mayor sensibilidad en la detección. En la siguiente sección se presentan estas definiciones.

### 3.3 Ajuste de parámetros del Detector Kullback-Leibler

En esta sección se describe el trabajo realizado para el diseño y parámetros óptimos del detector de fallas de encolamientos a través de la divergencia de Kullback-Leibler  $Detector_{KL}$

#### 3.3.1 Parámetros del $Detector_{KL}$

Se requiere fijar los parámetros del detector, como son la cantidad de intervalos (bins) de conteo de las frecuencias de los datos, representada por el conteo.

$$n_i = \sum_{j=1}^N \mathbb{I}_{\{i\}}(X_j) \quad (3.5)$$

Considera la cantidad de datos  $X_n$  que conforma la serie de pruebas con distribución  $Q(x)$ .

- (a) *Largo de ventana de la muestra:* se utiliza matlab para realizar un barrido del largo de ventana para la serie de muestra o validación  $Q(x)$ , con el objetivo de inferir el largo posible de la muestra para obtener una detección rápida y confiable. Por supuesto en este punto se presenta el problema de retardo para muestras de mayor largo y los problemas de precisión para muestras de menor cantidad.

En los eventos de encolamientos observados dentro del período de muestreo tienen una duración de 20 a 120 muestras en promedio inferior y superior, entonces el barrido queda acotado a este rango de valores.

- (b) *Cantidad de intervalos:* con la ayuda de matlab se realiza un barrido simultáneo con el largo de la muestra, específicamente cada incremento en el barrido de los intervalos (bins)  $(Z_{i-1}, Z_i)$ , con  $i = 1, 2, 3, \dots, N(\text{bins})$ ; se realiza un barrido completo del rango para el largo de la muestra. Con ello se proyecta obtener una tabla 3.1 de rangos de intervalos (bins) versus la eficiencia resultante en el barrido del largo de la muestra.

Esta tabla de eficiencia entregará los valores óptimos para el par (a) largo de la muestra y (b) cantidad de intervalos para generar las distribuciones  $P_1(x)$ ,  $P_2(x)$  y  $Q(x)$ .

#### 3.3.2 Determinación de parámetros óptimos del detector

La detección se activa cuando el detector alcanza el valor de umbral (“cero”) que es la diferencia entre la divergencia  $D_{KL1}(P_1(x) \parallel Q(x))$  y la divergencia  $D_{KL2}(P_2(x) \parallel Q(x))$ . Para establecer los parámetros (sección 3.3.1) eficientes para el detector, se considera que la posición de eficiencia es cuando el encolamiento alcanza el umbral de 2000 (valor que actualmente se utiliza para declarar una falla de encolamiento, en el sistema administrador de prepago).

$$\Delta_s = p_{x_i=2000} - p_{Umbral_{\kappa_i}=0} \quad (3.6)$$

**Tabla 3.1:** Parámetros óptimos largo de la muestra  $Q(x)$  y número de bins  $h$ .

NºBins▷	10	20	30	40	50	60	70	80	90	100
L_Ventana26	0	1	1	1	0	-1	-1	-1	-1	-1
L_Ventana27	0	2	2	2	1	0	0	0	0	0
L_Ventana28	0	3	3	3	2	1	1	1	1	1

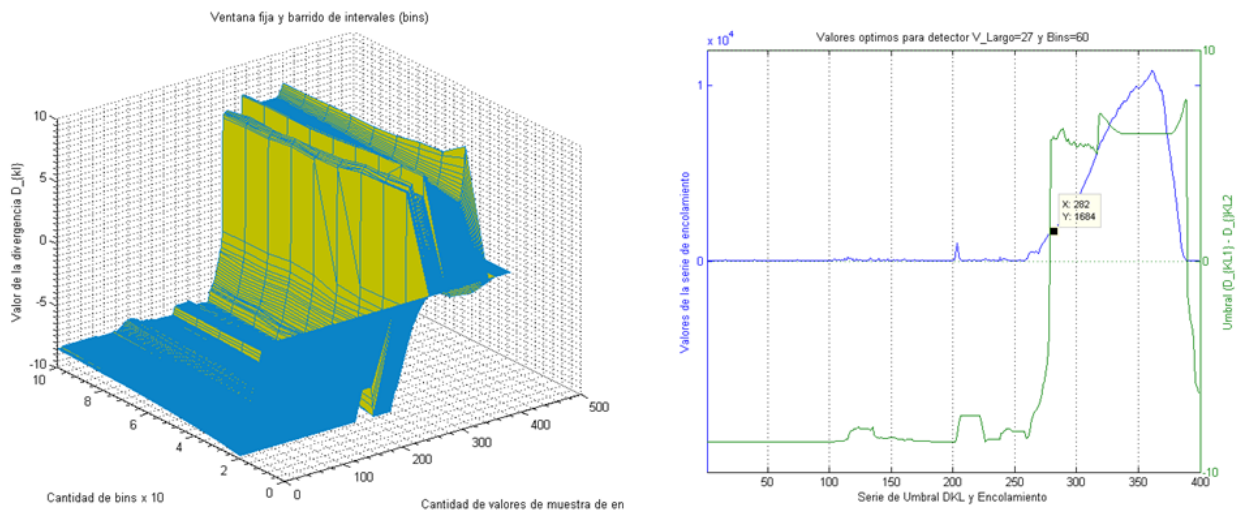
Considerando  $\Delta_s \sim 0$  como el mejor resultado.

Para realizar este proceso, además se consideran los siguientes puntos:

1. El barrido de largo de la muestra esta acotado de 20 a 100 muestras, con un incremento de paso de una unidad por ciclo.
2. El barrido de intervalos (bins) para el histograma se asigna un incremento de paso de 10 en 10, acotado desde 20 a 100 intervalos.
3. El valor de referencia de eficiencia se asume como el valor de 2000 que es un valor dado en la actualidad a la alarma que monitorea el sistema, si la cola aumenta sobre este valor se declara una falla. Por tanto, se mide la eficiencia respecto de la proximidad del  $Umbral = 0$  del detector con el valor de alarma declarada como falla.

Se reitera este proceso para verificar que los valores óptimos continúen apareciendo de la misma magnitud, para concluir que son los parámetros con mayor grado de sensibilidad para la detección de condiciones de fallas.

En la tabla 3.1 se muestra un extracto del resultado de los valores obtenidos de  $\Delta_s$ , concluyendo que el valor óptimo es para 27 muestras de largo para serie  $Q(x)$ .



**Figura 3.10:** Figura (a) barrido con Largo=27 con barrido de bins, (b) ejemplo de la detección de umbral y el valor de referencia de alarma.

Además, en la figura 3.10 se visualiza la curva de valores de la variable  $Umbral_{DKL}$  (ecuación 3.2) donde se puede apreciar que el valor de  $Umbral_{DKL} = 0$  cuando la serie de encolamiento real alcanza el valor de declaración de fallas.



## Capítulo 4

# Estudio de desempeño de Detector Kullback-Leibler

Para realizar el análisis de desempeño del detector, con el objetivo de establecer su eficiencia por sobre el sistema de detección por alarmas, se requiere someter a estrés de detección al  $Detector_{KL}$ , como al sistema de detección por alarmas.

Uno de los problemas que enfrenta esta tarea de verificación de desempeño del  $Detector_{KL}$  se trata de la disponibilidad de las series de entrenamiento, debido a que no se cuenta con un alto número de series de muestra de estados de falla de encolamientos durante el período de muestreo; para resolver este problema se hace necesario la generación de series de verificación simuladas.


### 4.1 Generación de series de encolamiento

Para crear series de encolamientos de prueba se busca automatizar la creación de ellas para validar y probar el detector propuesto. Para la generación de series de pruebas se consideran los siguientes supuestos:

- ⇒ Las series de prueba buscan simular el comportamiento de las series normales.
- ⇒ Las series de prueba se diferenciarán de las reales porque contienen una baja proporción de puntos en condición normal, ya que no existe mayor diferencia en los resultados entre un grupo de 50 o 1000 puntos en condición normal.
- ⇒ La serie de prueba contendrá 3 grupos de sub-series que se repiten durante su duración:
  1. Datos en condición normal
  2. Encolamientos
  3. Perturbaciones

⇒ Los encolamientos de prueba generan series similares a los encolamientos presentes en las series reales. En su conjunto se persigue que en promedio los encolamientos de prueba presenten el mismo comportamiento “promedio” de los encolamientos verdaderos utilizados para el entrenamiento del  $Detector_{KL}$

En esta sección se explica la metodología utilizada para la creación de series de pruebas, y posteriormente se define cada elemento presente en la elaboración de estas. Un ejemplo de serie de prueba se observa en la figura siguiente.



**Figura 4.1:** Serie de prueba con encolamientos y perturbaciones generada con cadenas de Márkov, para el estudio de desempeño del  $Detector_{KL}$

## 4.2 Composición de la serie de prueba

Las series de prueba se componen de 3 tipos de agrupaciones o sub-series de datos, que definen los estados para la generación de series de encolamiento de pruebas.

- (a) Valores dentro del rango de condición normal, implica *Estado 1*.
- (b) Valores en condición de encolamiento, implica *Estado 2*.
- (c) Valores de perturbaciones, implica *Estado 3*.

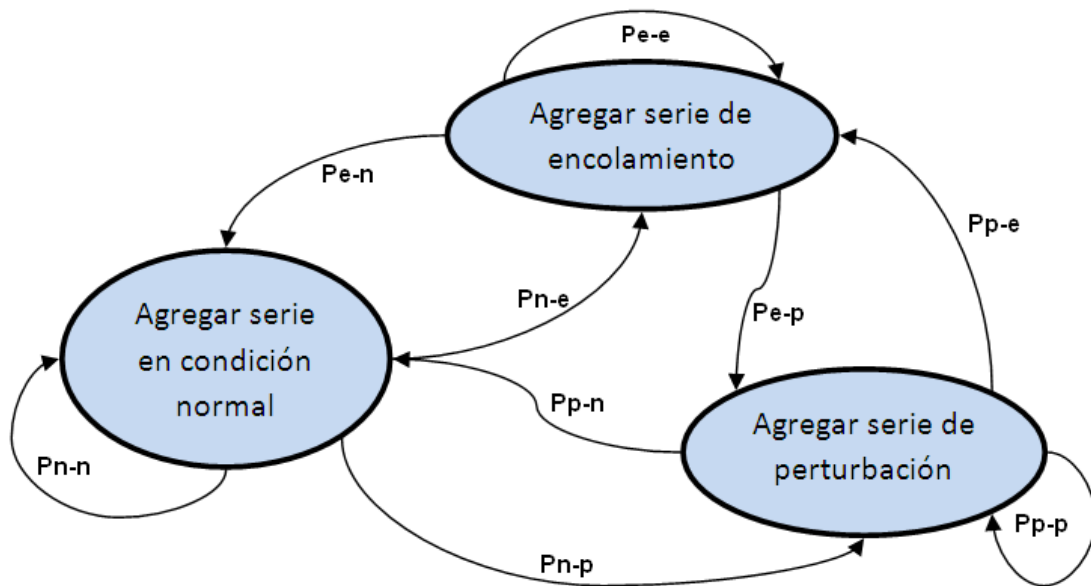
Bajo este esquema, se puede generalizar la composición de una serie de prueba como un proceso de Márkov, donde cada estado del proceso indica si el siguiente elemento a agregar en la serie va a ser una de las tres sub series mencionadas (cada uno con parámetros que las describen). Con este modelamiento es posible generar series de prueba con un alto grado de diferencia. Este proceso se repite hasta que la serie alcanza el largo deseado.

El modelo de Márkov para la generación de series de pruebas para el esquema indicado en la figura 4.2 está definido como:

$$P_s = \begin{bmatrix} p_{nn} & p_{ne} & p_{np} \\ p_{en} & p_{ee} & p_{ep} \\ p_{pn} & p_{pe} & p_{pp} \end{bmatrix} \quad (4.1)$$

donde se cumple que:

$$\sum_{j=1}^3 P_{ij} = 1, \quad \forall i \quad (4.2)$$



**Figura 4.2:** Matriz de estados de Márkov definida para generación de series de pruebas para calculo de desempeño.

El funcionamiento de la generación de series de prueba se describe como:

1. Inicialmente se considera que la serie comienza con una sub-serie de puntos en condición normal.
2. Luego mediante un proceso descrito por una cadena de Márkov se van agregando las distintas sub-series generadas al azar. Los estados de esta serie se consideran como el elemento a agregar.
  - ⇒ Estado 1: serie en condición normal
  - ⇒ Estado 2: serie de puntos de encolamiento
  - ⇒ Estado 3: series de puntos de perturbación
3. Cualquier estado puede pasar a los dos estados siguientes, con mayor probabilidad de paso al siguiente estado para evitar ciclos de subciclos.

## 4.2.1 Elementos de la serie de prueba

Para generar las series de pruebas se define como parámetro principal la cantidad de encolamientos, ya que, es el factor principal de estudio. Esta duración es en definitiva el largo de serie de pruebas  $Q'(x)$  y es valor de entrada al sistema de generación de series de pruebas.

En las primeras simulaciones se observó que las series generadas contenían una gran cantidad de puntos en condición normal, lo que en la práctica no aporta mayor información, ya que el objetivo de la serie de pruebas es que contenga datos en “condición de falla de encolamiento” para obtener el desempeño de detección. Para evitar “inundar” la serie con puntos en condición normal se decidió disminuir la probabilidad asociada a continuar en el estado 1; lo que es análogo a aumentar la probabilidad de pasar a los estados 2 y 3.

### 4.2.1.1 Generación de serie de puntos en condición normal

En base a la distribución y valores estadísticos de la muestra principal, se genera una cantidad de puntos al azar, entre 10 y 80, con puntos de valor aleatorio entre 0 y 200 (variable aleatoria con distribución lineal).

Cada elemento de una serie en condición normal está estructurada como:

$$S_n = a \quad a \in (0, 200], n < \text{largo serie} \quad (4.3)$$

Cada elemento se obtiene a través de una distribución de probabilidad constante para el rango definido (entre 0 y 200).

### 4.2.1.2 Generación de serie de puntos de encolamiento

Primero se obtiene el valor máximo del encolamiento, obtenido mediante una variable aleatoria entre un rango de altos acotados a los valores reales, ejemplo 12.000 que es el valor máximo aproximado de las series de encolamiento real (Sección 3.1.2.3); junto a un valor de *fit* asociado al crecimiento del encolamiento. De esta forma se construye en dos partes el encolamiento: al aumentar hasta su valor máximo, y luego cuando disminuye.

La primera parte del encolamiento está descrita por:

$$ENC(t) = \text{rand}(t) + ENC(t-1) - \text{rand}(t-1) + \text{rand}(t-1) * \text{fit}, \text{ hasta que } ENC(t) > \text{altura Máxima}$$

Donde:

$ENC(t)$  = encolamiento en el instante  $t$ .

$\text{rand}(t)$  = nuevos elementos que son encolados durante el momento  $t$ .

$rand(t - 1)$  = elementos encolados durante el instante  $(t - 1)$ .

$fit$  = indicador de elementos encolados que han salido de la cola.


En el momento “ $t$ ” se produce un encolamiento de una cantidad “ $rand(t)$ ”, pero la cola procesó, es decir salieron de ella una proporción de los elementos que llegaron en  $t - 1$ , esto se representa por  $rand(t - 1)fit$ . Mediante la variable de  $fit$ , es posible obtener la amplia gama de encolamientos (encolamiento lentos en crecer con menor pendiente hasta encolamientos rápidos de mayor pendiente).

La segunda parte del encolamiento, cuando comienza a decrecer, se describe por:

$$ENC(t) = ENC(t-1) - rand(t) \text{ hasta que } ENC(t+1) < 0$$


A continuación se ilustran distintos tipos de encolamientos resultantes según el valor del  $fit$  (para una altura máxima de 8000).

⇒  $Fit = 2.3$ , se considera como un aumento de la cantidad adicional que llega el momento de encolamiento.




**Figura 4.3:** Ejemplo de encolamiento con  $fit$  2.3

⇒  $Fit = 1$ , encolamiento normal con duración y crecimiento promedio a los reales.



**Figura 4.4:** Ejemplo de encolamiento con *fit 1*

⇒  $Fit = 0.6$ , encolamiento de lento crecimiento, cuando existen un encolamiento con una duración más alla del promedio real.



**Figura 4.5:** Ejemplo de encolamiento con *fit 0.6*

#### 4.2.1.3 Generación de serie de puntos de perturbación

Al generar una serie de perturbación se obtienen 2 valores que la describen: (a) su altura máxima (peak) y (b) su largo o duración. De forma similar al caso anterior, se consideran dos partes en su construcción: (i) cuando crece la perturbación y (ii) luego cuando disminuye.

La división entre ambas partes (creciente y decreciente) es el punto máximo. Este punto máximo es situado en una ubicación al azar en el tercio central de la serie (determinado por una v.a. con distribución continua sobre ese sector). Luego cada sección se divide en puntos equidistantes en altura, y a cada punto se hace variar levemente en torno a si mismo . Esta última variación

permite que los puntos obtenidos siempre varíen, incluso para alturas y largo de perturbaciones idénticos.

Por último sus valores están acotados, entre el máximo de un valor normal y al menos un punto más del valor de la alarma que declara la falla; entonces los datos de perturbaciones quedan acotados entre [500,2500].

### 4.3 Estudio de desempeño $Detector_{KL}$ con series simuladas

El objetivo es estudiar el desempeño del  $Detector_{KL}$  de encolamiento con sus parámetros definidos en la sección 3.3.2. donde se estableció la cantidad de intervalos (bins) y el largo ( $L_n$ ) de la serie de verificación  $Q_x$  del detector. Los resultados esperados del estudio de desempeño son:

#### 1. Desempeño de $Detector_{KL}$ bajo condiciones en encolamientos.

Este es el principal objetivo dado que se persigue la detección confiable y precisa de los eventos de falla reales y se verifica esta capacidad de detección con series de prueba, para extrapolar la capacidad en el desempeño que debe presentar al ser implementado en regimen permanente.

En este punto es deseable separar el desempeño de  $Detector_{KL}$  en condiciones de (i) Encolamientos normales y (ii) Encolamientos prolongados.

#### 2. Desempeño de $Detector_{KL}$ bajo condiciones de perturbaciones

En las series reales existen condiciones de perturbaciones, que toman valores sobre las cotas promedio de los datos en condición normal. Para estos eventos los sistemas de alarmas representan un problema de falsos positivos, que es interesante comparar con el desempeño del  $Detector_{KL}$  sobre estas condiciones especiales.

Además se espera obtener el desempeño del  $Detector_{KL}$  para errores del Tipo I y del Tipo II (sección 2.2.1.1).

### 4.4 Criterios de desempeño $Detector_{KL}$

Los criterios de desempeño se establecen tomando en cuenta el proceso realizado en la sección de análisis de las series de condición normal y fallas (secciones 3.1.2.4 y 3.1.2.3, respectivamente). Para estas condiciones se definieron valores de cotas y valores para declaración de falla; entonces considerando estos datos tenemos.

#### 4.4.1 Criterios desempeño $D_{KL}$ para encolamientos

El criterio para desempeño del detector utilizando series de pruebas de encolamiento se definen a continuación.

- (a) La posición de detección óptima para la declaración de un encolamiento, es la posición  $p_s$  del valor  $X'_n$  una vez alcanzada la magnitud de 2000 encolados.
- (b) El desempeño es el intervalo o retraso de la detección del encolamiento.

⇒ Para el caso del “Detector<sub>KL</sub>”, se define como:

$$\Delta_{D_{KL}} = \left[ p_{s=x_j(\text{umbral}_{D_{KL}}=0)} - p_{s=x_{j=1}} \right] \quad (4.4)$$

Donde:

$\Delta_{D_{KL}}$ : Cantidad de posiciones de detección resultante.

$p_{s=x_j(\text{umbral}_{D_{KL}}=0)}$ : Posición en la que la variable de umbral es cero.

$p_{s=x_{j=1}}$ : Posición del inicio del encolamiento.

⇒ Para el caso de detección por “Alarma”, se define como:

$$\Delta_{alarma} = \left[ p_{s=x_j(2000)} - p_{s=x_{j=1}} \right] \quad (4.5)$$

Donde:

$\Delta_{alarma}$ : Cantidad de posiciones de detección resultante.

$p_{s=x_j(2000)}$ : Posición en la que el valor del dato alcanza a 2000.

$p_{s=x_{j=1}}$ : Posición del inicio del encolamiento.

Una vez obtenido los valores de  $\Delta_{D_{KL}}$  y  $\Delta_{alarma}$  para el largo total de las series de pruebas, estas se deben ponderar para comparar la eficiencia y la precisión de ambos sistemas de detección de condiciones de falla del proceso de cambio de estados.

#### 4.4.2 Criterios desempeño $D_{KL}$ para perturbaciones

El criterio para el desempeño del detector sobre perturbaciones que se generan aleatoriamente, se define en los siguientes alcances.

- (a) Estas perturbaciones para todos los casos se espera que “NO” sean detectados, debido a que dichos disturbios no constituyen de forma aislada una falla de encolamiento.
- (b) El desempeño es el intervalo o retraso de la detección para perturbaciones debería ser  $\emptyset$ ; tanto para el caso del *Detector<sub>KL</sub>* como para *Alarma*



**Tabla 4.1:** Desempeño del detector para encolamientos de prueba

	<i>Detector_KL</i>	<i>Alarma</i>
<i>Promedio de retraso de detección</i>	Promedio de posiciones en las que el detector detecta el encolamiento	Promedio de posiciones en las que la alarma detecta el encolamiento
<i>% Error detección, Error Tipo I</i>	% promedio detector.kl no detecta durante una falla de encolamiento	% promedio en los cuales la alarma no detecta las fallas de encolamientos
<i>% Falsos positivos, Error tipo II</i>	% promedio detector.kl vuelve a la condición normal luego se dispara nuevamente dentro del período de duración del encolamiento	% promedio ocasiones que Alarma cesa y vuelve aparecer, al superar el valor del umbral

**Tabla 4.2:** Desempeño del detector para perturbaciones de prueba

	<i>Detector_KL</i>	<i>Alarma</i>
<i>% Detección</i>	% No Detección (No debería detectar)	% No Detección (No debería detectar)
<i>% Falsos positivos</i>	% que el detector se activó por una perturbación	% que la alarma se activó por perturbación

Se espera obtener una tabla con el resultado de las detecciones ante eventos de perturbación, tanto para el *Detector<sub>KL</sub>*, como para la detección por *Alarma*. Para el caso de la *Alarma* es obvio que si existe un valor por sobre 2000 la detección se activará, esto bajo condiciones reales y de generación de series de pruebas puede ocurrir. Para el caso de series de prueba el valor de perturbaciones esta acotada [500,2500]

## 4.5 Resultados de desempeño *Detector<sub>KL</sub>*

A través de la creación de las series de encolamiento de pruebas con un largo similar se obtuvieron las tablas de desempeño con un promedio de 1000 encolamientos normales, 400 encolamientos prolongados, y 1000 eventos de perturbaciones por cada iteración. La serie  $Q'(x)$  tiene un largo de 300k a 500k datos.

**Tabla 4.3:** Desempeño del detector para encolamientos normales de prueba

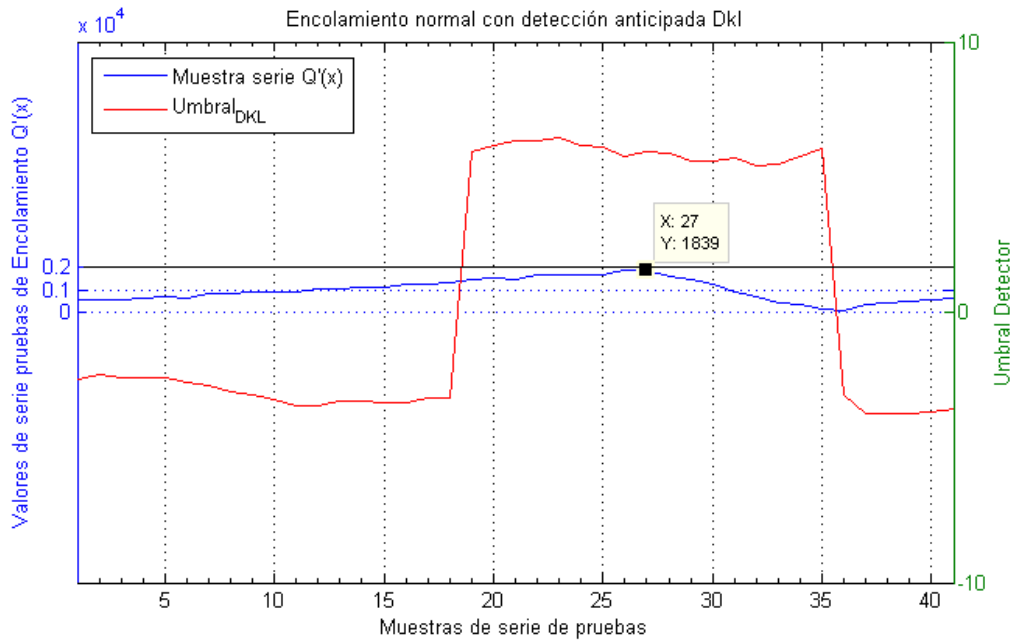
Encolamientos < 180	D.KL	Alarma
Promedio Retardo detección N posiciones	24,96	19,09
% Error detección	1,90%	4,77%
% Falsos Positivos	0,1%	2,64%

En la tabla 4.3 se presenta el desempeño del  $Detector_{KL}$  para estos tipos de encolamiento normales, es decir de duración promedio. Los datos de encolamiento normales están acotados a un largo de duración entre [30, 180] minutos, con un valor máximo de 15000 comandos encolados.

El resultado muestra que el  $Detector_{KL}$  tiene un retardo promedio de detección de 24 muestras desde que se inicia el encolamiento; por su parte la detección por alarma tiene un retardo promedio de 19 muestras. Para este caso la detección por alarma tiene una respuesta levemente más rápida. Esta situación no es crítica dado que el período de muestreo de la alarma es cada 5 minutos, que es bastante cercano al retraso promedio que presenta el  $Detector_{KL}$  en comparación del sistema de alarmas.

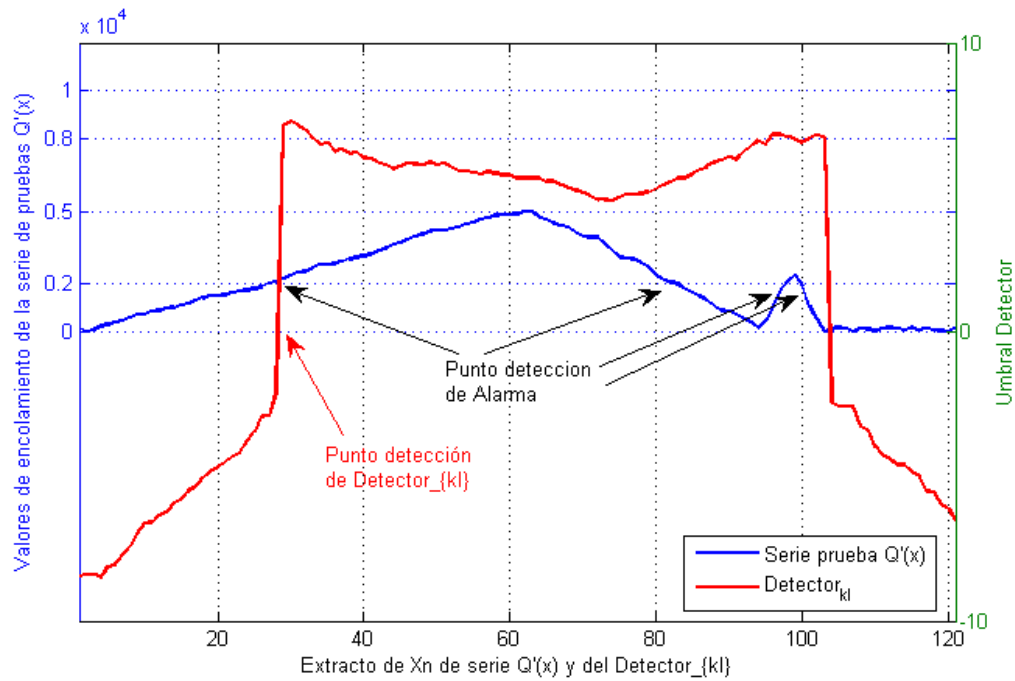
Ambos sistemas presentan un “Error en la detección” (error tipo I) de la condición de fallas. Revisando este comportamiento se debe a casos en donde el encolamiento presenta una duración cercana a la cota mínima ([30) y en donde el valor de encolamiento es inferior al valor umbral (2000). Para estos casos el error de detección es del 1,9% del total de encolamientos, y para el caso de detección por alarma es del orden del 4,77%, lo que permite afirmar que el desempeño del  $Detector_{KL}$  es superior al sistema de alarma que utiliza un umbral definido.

Este mejor desempeño se puede apreciar en la figura 4.6, donde la generación de encolamientos normales de forma aleatoria generó un encolamiento que no alcanza a sobrepasar el valor de la alarma (2000), por ende no se activa la detección por alarma perdiendo la información de la falla. En cambio el  $Detector_{KL}$  se activa y alerta de la condición.



**Figura 4.6:**  $Detector_{KL}$  se activa para encolamientos con magnitud inferior al umbral de alarma.

Para los casos de “falsos positivos” (error tipo II), estas condiciones se producen cuando, existiendo un encolamiento se presenta un borrado de la alerta que se puede interpretar como el regreso a una condición normal en condiciones que el proceso se encuentra aún en un estado de falla. Para estos casos el porcentaje es de 0.1% de los encolamientos para  $Detector_{KL}$  y de 2,64% para falsos positivos generados por la alarma.



**Figura 4.7:**  $Detector_{KL}$  se activa cercano a la posición de la alarma umbral (2000) y se mantiene hasta que finaliza la condición de falla.

En la figura 4.7 se puede apreciar que el  $Detector_{KL}$  mantiene su condición de falla mientras el proceso no retorna a su condición normal, en cambio la detección por alarma de umbral (2000) presenta cuatro activaciones, originándose de esta forma un mayor porcentaje de falsos positivos para la detección por alarma de umbral (2000).

En resumen se puede apreciar el desempeño del  $Detector_{KL}$ , presenta un leve retraso promedio en la detección del encolamiento y un menor porcentaje de error de tipo I y II; se concluye una mejor respuesta y una mayor sensibilidad en la detección en el caso de detección por divergencia Kullback-Leibler.

**Tabla 4.4:** Desempeño del detector para encolamientos de prueba prolongados

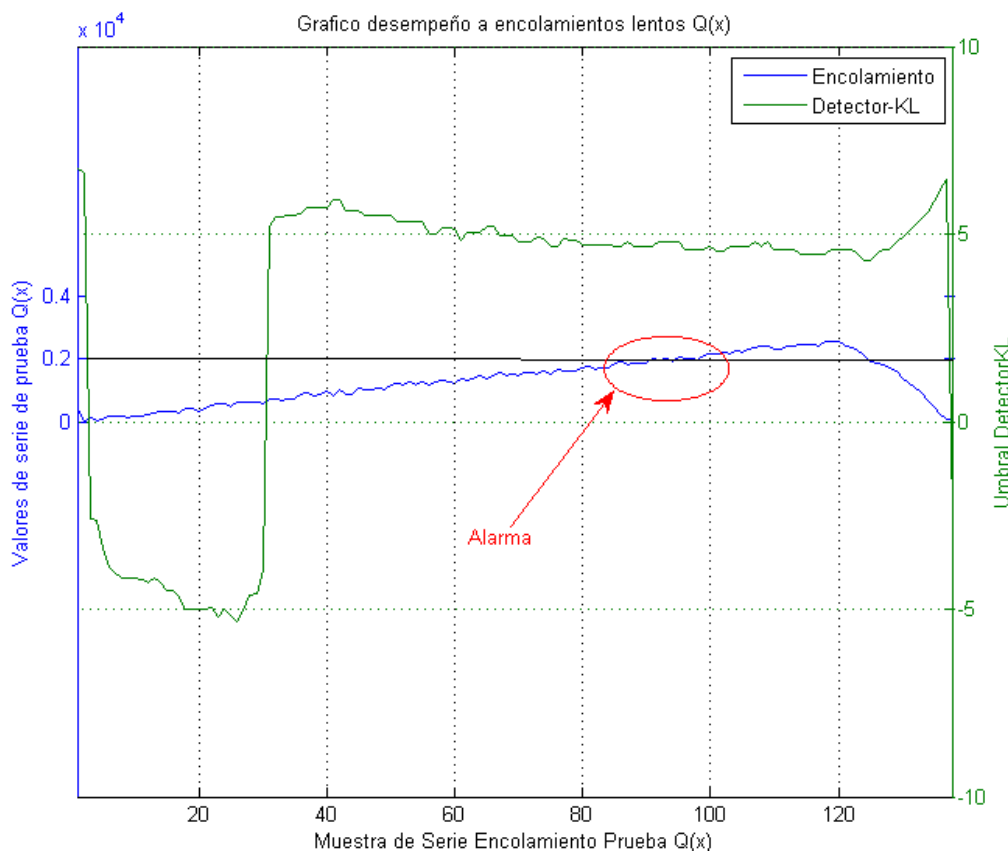
Encolamientos > 180	D_KL	Alarma
Promedio Retardo detección	25,92	56,70
% Error detección	0	0
% Falsos Positivos	0	33,78

En la tabla 4.4 se presenta el desempeño del  $Detector_{KL}$  para estos tipos de encolamiento prolongados. Cada encolamiento tiene una duración entre [181, 1100] con un valor máximo de 15000.

El resultado muestra que el  $Detector_{KL}$  tiene un retardo promedio de detección de 25 muestras

desde que se inicia un encolamiento prolongado; por su parte la detección por alarma tiene un retardo promedio de 56 muestras. Entonces para este caso la detección por  $Detector_{KL}$  tiene una respuesta más rápida que la alarma. En promedio el  $Detector_{KL}$  tiene una detección de 30 minutos antes que la detección por alarma.

Para los casos de encolamiento prolongado como se visualiza en la figura 4.8, el  $Detector_{KL}$  obtiene un desempeño superior al sistema de detección de *Alarmas*. Además en los casos que existen perturbaciones del valor de encolamiento durante el período de duración del encolamiento prolongado la alarma cesa y se vuelve activar, por lo que puede producir una percepción indeterminada de la condición de estado del proceso.



**Figura 4.8:**  $Detector_{KL}$  se activa en promedio 30 registros antes que la detección por el sistema de alarmas, para condiciones de encolamiento prolongados.

Ambos sistemas no presentan “error en la detección” (error tipo I) de condición de fallas; ya que en los encolamientos prolongados siempre se alcanza el valor umbral (2000), por ello no hay error de no detección de algún evento de encolamiento.

Para los casos de “falsos positivos” (error tipo II), estas condiciones se producen cuando existiendo un encolamiento se presenta un borrado de la alerta, que se puede interpretar como el regreso a una condición normal en condiciones que el proceso aún se encuentra en un estado

de falla. Esta condición se produce cuando los valores de encolamiento dentro del intervalo de duración del encolamiento prolongado presenta valores a la baja, y luego de algunas muestras crece nuevamente.

En este caso el  $Detector_{KL}$  no presenta retornos a valores que indiquen una condición normal, por el contrario en la detección por alarma la alerta es borrada erróneamente (ver “alarma” el rojo, en la figura 4.8) cada vez que el valor de encolamiento baja del valor umbral, mientras en el encolamiento aún persiste.

**Tabla 4.5:** Desempeño del detector para perturbaciones de prueba

	Detector_KL	Alarma
% NO detección	96,28	76,60
% Falso Positivo	3,72	23,40

En la tabla 4.5 se presenta el desempeño del detector en condiciones de perturbaciones. Estas perturbaciones tienen una duración de [7,25] minutos, con un valor máximo de 2500.

En condiciones de perturbación se espera que, tanto el  $Detector_{KL}$ , como la alarma no se activen frente a estas perturbaciones, dado que no representan un problema de encolamiento, sino una condición de ruido. Las alertas de esta condición de perturbación genera “falsos positivos” que provoca la activación de los procedimientos (sección 1.7) de corrección de fallas, perdiendo la sensibilidad frente a una falla real cuando el “falso positivo” se reitera permanentemente.

El desempeño ante perturbaciones para el caso del  $Detector_{KL}$  es de un 96,28% de los eventos correctamente no detectados. Este valor es alto en comparación sólo al 76,60% de no detección de la alarma de umbral. Esta diferencia se debe a que cualquier valor dentro de la perturbación que exceda el valor del umbral (2000) la alarma se activará; en cambio en el caso del  $Detector_{KL}$  como evalúa un largo de la muestra para representar la condición de operación, los valores aislados como las perturbaciones no tienen el peso para que el  $Detector_{KL}$  llegue a su valor de detección.

Este comportamiento representa un buen aporte para las áreas de operación, que al aplicar esta herramienta de detección, elimina casi totalmente los eventos de falsos positivos que provoca la detección por alarmas de umbral. Para el caso del  $Detector_{KL}$  el índice de “falso positivo” es del 3,72% en comparación al 23,40% de los eventos de perturbación en los que la alarma activó la alerta.

Finalmente, de acuerdo a los resultados obtenidos se puede apreciar el importante aumento en la sensibilidad del detector en comparación al desempeño de una alerta por alarma. Se logra un resultado que reduce en el error de detección en un 60% (1,9% de error de detección en  $D_{KL}$  y 4,77% de error de detección de la alarma) ante encolamientos de duración promedio, y disminuye en 85% (3,72% de falso positivo de detección en  $D_{KL}$  y 23,40% de falsos positivos en el caso de la alarma) ante situaciones de perturbación en los valores de encolamiento, que provocan la mayor cantidad de alarmas falsas, donde no existe condición de falla.

## Capítulo 5

# Conclusiones y Aportes del trabajo

A continuación se presenta el detalle de las conclusiones y aportes sobre el trabajo desarrollado en lo que se refiere a las fortalezas y debilidades de la aplicación de esta herramienta de divergencias para la detección de situaciones de falla en procesos críticos.

### 5.1 Conclusiones del trabajo

Las conclusiones globales y específicas de cada módulo de desarrollado del presente trabajo se indican a continuación.

#### 5.1.1 Conclusiones globales

La implementación del *Detector<sub>KL</sub>* ha logrado los objetivos esperados mejorando la confiabilidad y precisión en la detección de las condiciones de encolamiento del proceso de cambios de estado de prepago. Con un desempeño (sección 4.5) por sobre el sistema actual de detección de fallas vía alarmas de umbral, logra un resultado que reduce el error de detección en un 60% ante encolamientos de duración promedio, y disminuye el error de detección en un 85% ante situaciones de perturbación en los valores de encolamiento, que provocan la mayor cantidad de alarmas falsas.

Al repasar los resultados (sección 4.5) es posible apreciar claramente que la mayor ventaja del *Detector<sub>KL</sub>* se da en las situaciones de perturbación y encolamientos grandes. Ambas series de datos son los extremos del comportamiento del proceso. En el caso de las perturbaciones estas inducen en la detección por alarmas umbral (2000) una importante cantidad de “falsos positivos” que provocan incertidumbre en las áreas de operación, al ver que la alerta de la alarma se activa continuamente. Por otro lado el *Detector<sub>KL</sub>* opera de forma robusta no alertando estas condiciones de perturbación. En el caso de encolamientos prolongados el *Detector<sub>KL</sub>* se anticipa en 30 minutos (promedio) en la detección del encolamiento; en cambio la detección por alarma umbral (2000) por su naturaleza no tiene posibilidad de alertar antes.

En la práctica sin la incorporación de estas herramientas de detección de fallas por divergencias las unidades de operaciones realizan ajustes al valor umbral de la alarma de forma empírica mediante método de prueba y error. El inconveniente es que al bajar el valor del umbral se genera una mayor cantidad de “falsos positivos” por una mayor frecuencia en la activación de la alarma.

La implementación en línea de esta herramienta de detección es posible, ya que, el cálculo de cada iteración requiere un tiempo reducido porque las distribuciones de las condiciones normal y de fallas se encuentran previamente calculadas y almacenadas en las variables del detector. Por tanto, sólo se calcula la distribución empírica de la muestra  $Q(x)$  que se compara con las dos condiciones almacenadas,  $P_1(x)$  para la condición normal y  $P_2(x)$  para la condición de falla.

En la medida que se produzcan nuevos eventos reales de condición de fallas es posible realizar el ajuste en los valores de los parámetros de construcción del  $Detector_{KL}$ , que son el largo de datos de la muestra  $X_n$  y la cantidad de intervalos de representación (bins).

Si bien las plataformas y equipamiento de redes de Telecomunicaciones tienen un desarrollo vertiginoso, en aquellos sistemas o servicios en los que se involucra equipamiento de varios proveedores, no se visualizan herramientas de detección que identifiquen el estado de operación del proceso de comunicación que mantienen dos sistemas en común. Esta brecha representa una oportunidad para aplicar este tipo de técnicas y mejorar la detección en las transiciones desde condición de operación normal hacia una condición de falla replicando el modelo de detector  $Detector_{KL}$  en otros procesos críticos.

## 5.1.2 Conclusiones por sección

A continuación, para una mayor descripción se incluyen las conclusiones más relevantes observadas en el desarrollo de las secciones del trabajo.

### 5.1.2.1 Conclusiones sobre requerimientos del trabajo

El proceso de implementación de toma de medidas y observación fue requisito para desarrollar este estudio. En futuros trabajos la observación del proceso dependerá de la complejidad para realizar el monitoreo de las variables sobre los nodos que involucran el proceso. Esto puede requerir un mayor esfuerzo inicial en la implementación práctica de soluciones para el proceso de muestreo, almacenamiento de registros, bases de datos y herramientas para manejo de grandes volúmenes de registros.

El período de observación necesario para concretar los objetivos del estudio están relacionados al tiempo necesario para obtener una muestra suficientemente amplia para representar las condiciones de estado de operación del proceso de estudio. Antes de comenzar a abordar la estrategia e implementación se necesitó un período de 14 meses para obtener los datos suficientes.

Es importante destacar que dado el volumen de datos almacenados se requiere considerar un programa de visualización de los datos de modo gráfico, como herramienta de apoyo en el trabajo inicial de procesamiento de los datos. Si bien no es parte directa de los objetivos del estudio



el hecho de implementar una herramienta que permita la visualización de forma “tilt down” permitirá facilitar la clasificación y limpieza de los datos. La implementación de este tipo de herramientas de apoyo para la revisión de los datos puede tomar un período considerable.

En cuanto al manejo de los datos se desarrolló tomando en cuenta los objetivos del estudio, por tanto los eventos de encolamiento de cada fin de mes fueron removidos de las series de datos de trabajo, por representar un condición conocida que no aporta conocimiento al objetivo de detección de condición de fallas.

Un aspecto de cuidado es la sincronización entre el tiempo de medición y almacenamiento del valor del registro, es un tema relevante para mantener la consistencia de los datos, ya que, puede representar una fuente de errores. En los sistemas tradicionales de alarma esto impide que exista un menor tiempo de muestreo.

Se ha construido un importante modelo de conocimiento del sistema de encolamiento que representan un apoyo para acelerar los procesos de resolución de problemas. Con esto se minimiza el gran impacto (sección 1.6.2) que este tipo de fallas provoca a los clientes y a la organización.

#### 5.1.2.2 Conclusiones sobre la construcción del $detector_{KL}$

En el cálculo de los parámetros de construcción del  $Detector_{KL}$  se determinó un largo de la muestra  $Q(x)$  y la cantidad de intervalos de representación (bins). En la medida que se mantenga la observación del proceso y almacenamiento de los datos, es posible ajustar nuevamente estos valores, para incorporar nuevos eventos de encolamientos y con ello mejorar la detección de las condiciones de fallas. En este sentido se recomienda agregar cada serie de datos de nuevas fallas dentro de la serie de datos  $P_2(x)$ .

La divergencia de Kullback-Leibler para distribuciones de probabilidad discreta se calcula en base a la ecuación 2.8; donde la cantidad de intervalos debe ser igual para las distribuciones de probabilidad  $p(x)$  y  $q(x)$ . Aplicar esta restricción influye en los parámetros de diseño del detector (a) Largo de la muestra y (b) Cantidad de intervalos (bins).

#### 5.1.2.3 Conclusiones sobre desempeño del $detector_{KL}$

Según los resultados del desempeño del  $Detector_{KL}$  es posible mencionar:

- ⇒ El  $Detector_{KL}$  es cero cuando el valor de divergencia entre la muestra  $Q(x)$  y las condiciones de operación Normal  $P_1(x)$  y  $P_2(x)$  es igual, ya que como definición de detección se establece la resta de ambos resultados.
- ⇒ El  $Detector_{KL}$  presenta transiciones (cambio de signo) al presentarse un claro evento de encolamiento sin inestabilidad al procesar pequeñas perturbaciones que en ocasiones se producen tanto en condiciones normales como en condiciones de falla.
- ⇒ El  $Detector_{KL}$  activa la condición de falla y permanece entregando valores positivos hasta

que el proceso retorna a la condición normal. Este comportamiento es el esperado y presenta un mejor nivel de desempeño que la alarma por comparación de umbral.

- ⇒ La detección se muestra eficiente entre un largo de ventana de datos entre 27 a 35 con una representación de bins entre 50 a 60 bins para sus distribuciones de probabilidad, lo que se traduce en un sistema que contiene una memoria de aproximadamente una hora en base a que el muestreo de los datos se esta realizando cada un minuto.
- ⇒ Ante eventos de perturbaciones, es decir valores altos de encolamientos de forma intermitente o por un breve período de muestras el  $Detector_{KL}$  no alcanza su valor de detección evitando los falsos positivos en comparación a los falsos positivos que presenta la alarma discreta.
- ⇒ En el caso de “falso positivo” de la detección por sistemas de alarmas; existen eventos en estado de falla de encolamiento en donde la alarma cesa, pero comienza un nuevo evento de encolamiento. En este caso, la detección por alarma cesada se reactivará sólo cuando nuevamente el valor supere el umbral (2000). En cambio el desempeño observado para el  $Detector_{KL}$  se mantiene en condición de falla favoreciendo a la hipótesis  $H_2$ , consistentemente con el estado real del proceso simulado.
- ⇒ El  $Detector_{KL}$  permite establecer los cálculos en tiempo real, ya que el intervalo de muestreo es de un minuto, tiempo más que suficiente para el calculo de las divergencias de Kullback-Leibler para cada condición.
- ⇒ En el caso de detección de *Alarma* existen casos de encolamiento de duración mayor a 30 min, donde el valor del encolamiento no supera el valor de Alarma (2000) y por lo tanto, no es detectado por la alarma de valor fijo, contrariamente el  $Detector_{KL}$  detecta este evento y se activa, lo que representa una excelente ventaja en la detección de condiciones de encolamiento.
- ⇒ El  $Detector_{KL}$  tiene un desempeño muy superior frente a encolamientos de larga duración, ya que estos eventos son detectados más rápido por el  $Detector_{KL}$ ; mientras que la alarma por comparación de umbral sólo aparece cuando el valor del encolamiento supera el umbral 2000, pero el encolamiento se inicia mucho tiempo antes. Esto representa un buen resultado dado que se pueden tomar acciones correctivas mucho antes que la detección por alarma.

## 5.2 Aportes del trabajo

Las herramientas de divergencia sobre la detección en estado de procesos tiene aplicación en el campo de imágenes, aplicaciones industriales y medicina. Incluir estas herramientas sobre detección de condiciones operacionales en sistemas de telecomunicaciones es un campo en el que se puede aplicar como lo muestra el trabajo realizado.

Paradójicamente, en aquellos procesos que intervienen distintos proveedores y distintas tecnologías no se cuenta con una solución de detección de fallas unificadas, necesitando integrar

otras herramientas. En cuanto a las aplicaciones que se han diseñado para este fin se encuentra Tiboli (de IBM) o TNG (de Computers Associates) que agregan componentes como agentes neuronales que pueden predecir el comportamiento, pero su desventaja es que son muy difíciles de integrar, son invasivos ya que requieren de la instalación de agentes en los equipos a monitorear y complejos de parametrizar. Es por ello que herramientas como el análisis de los datos que fácilmente puede entregar el sistema y aplicando esta herramienta de divergencia es posible aplicar una real mejora al nivel de monitoreo y detección de condiciones de operación de procesos o sistemas críticos.

### 5.3 Potenciales extensiones del trabajo

En base al trabajo realizado es posible visualizar los siguientes puntos de acción para complementar y agregar nuevos conceptos, que permitan agregar nuevas funcionalidades como por ejemplo:

- ⇒ Incorporación de los eventos de encolamiento posteriores al proceso de observación, para incluir la sensibilidad de la distribución de los valores en los nuevos eventos de encolamiento.
- ⇒ Realizar un trabajo similar de cálculo de los parámetros de construcción del detector, a través de algunas reglas de asignación de intervalos como Dixon y Kronnal [29] (1965), Velleman [30] (1976), Sturges [31] (1926).
- ⇒ Como paso siguiente a la detección es posible realizar un estudio de pronósticos de serie de tiempo de la evolución del crecimiento del encolamiento y el tiempo de duración de fallas. Con ello se obtendría una herramienta de detección y de pronóstico de la evolución del encolamiento.
- ⇒ El proceso de construcción del detector de fallas se puede replicar a otros procesos operacionales en el sector de la banca, informática, control, etc. que dependen de procesos de intercambio de datos de forma constante, permitiendo incluir un elemento del control que mejore la detección en las condiciones de operación a través del estudio de las divergencias.

# Bibliografía

- [1] J. Eberspacher, H.-J. Vogel, C. Bettstetter, and C. Hartmann, *GSM - Architecture, Protocols and Services*. Wiley, 2009.
- [2] O. P. Kogeda and J. I. Agbinya, "Automation of cellular network faults," *Computer Science Department, University of Fort Hare, South Africa*, no. 335, 2007.
- [3] D. Kazakos, "Statistical discrimination using inaccurate models," *Information Theory, IEEE Transactions on*, vol. 28, no. 5, pp. 720 – 728, sep 1982.
- [4] S. Watts and D. Wicks, "Empirical models for detection prediction in k-distribution radar sea clutter," in *Radar Conference, 1990., Record of the IEEE 1990 International*, may 1990, pp. 189 –194.
- [5] X. Ye, K. Veeramachaneni, Y. Yan, and L. Osadciw, "Unsupervised learning and fusion for failure detection in wind turbines," in *Information Fusion, 2009. FUSION '09. 12th International Conference on*, july 2009, pp. 1497 –1503.
- [6] P. Zhuang, D. Wang, and Y. Shang, "Distributed distribution-based optimization for sensor fault detection," in *Circuits and Systems, 2009. MWSCAS '09. 52nd IEEE International Midwest Symposium on*, aug. 2009, pp. 280 –283.
- [7] S. Chretien and I. Hero, A.O., "Kullback proximal algorithms for maximum-likelihood estimation," *Information Theory, IEEE Transactions on*, vol. 46, no. 5, pp. 1800 –1810, aug 2000.
- [8] S.-M. Lee, A. Abbott, N. Clark, and P. Araman, "Diffusion on statistical manifolds," in *Image Processing, 2006 IEEE International Conference on*, oct. 2006, pp. 233 –236.
- [9] H. Akcay and S. Aksoy, "Automated detection of objects using multiple hierarchical segmentations," in *Geoscience and Remote Sensing Symposium, 2007. IGARSS 2007. IEEE International*, july 2007, pp. 1468 –1471.
- [10] M. Do and M. Vetterli, "Texture similarity measurement using Kullback-Leibler distance on wavelet subbands," in *Image Processing, 2000. Proceedings. 2000 International Conference on*, vol. 3, 2000, pp. 730 –733 vol.3.
- [11] P. Aarabi, "Localization-based sensor validation using the Kullback-Leibler divergence," *Systems, Man, and Cybernetics, Part B: Cybernetics, IEEE Transactions on*, vol. 34, no. 2, pp. 1007 – 1016, april 2004.

- [12] T. Ishigaki, T. Higuchi, and K. Watanabe, "Spectrum classification for early fault diagnosis of the LP gas pressure regulator based on the kullback-leibler kernel," in *Machine Learning for Signal Processing, 2006. Proceedings of the 2006 16th IEEE Signal Processing Society Workshop on*, sept. 2006, pp. 453–458.
- [13] I. Zhovna and I. D. Shallom, "Automatic detection and classification of sleep stages by multichannel EEG signal modeling," in *Engineering in Medicine and Biology Society, 2008. EMBS 2008. 30th Annual International Conference of the IEEE*, aug. 2008, pp. 2665–2668.
- [14] T. Hatanaka and K. Uosaki, "Optimal auxiliary input for fault detection based on Kullback divergence," in *Industrial Electronics Society, 2000. IECON 2000. 26th Annual Conference of the IEEE*, vol. 3, 2000, pp. 1731–1736 vol.3.
- [15] D. McMichael, "Bartm applied to visual inspection of axisymmetric engineering parts," in *Artificial Neural Networks, 1993., Third International Conference on*, may 1993, pp. 1–5.
- [16] 3rd Generation Partnership Project, "Charging management, charging architecture and principles, (release 9)," Technical Specification, December 2009.
- [17] Ericsson, "Ericsson multi mediation 5.0 - file and event mediation," Technical Specification, June 2008, product, Operation and Maintenance.
- [18] L. Dryburgh and J. Hewett, *Signaling System No. 7 (SS7/C7): Protocol, Architecture, and Services (Networking Technology)*. Cisco Press, 2004.
- [19] ITU-T, "Specifications of signalling system N7, recommendation Q.700," Technical Specification, March 1993, standard Protcols.
- [20] I. T. Union, "Information technology - open system interconnection - system management: Alarm function," CCIT, Tech. Rep. X.733, 1992.
- [21] E. T. S. Institute, "Template for service level agreements (SLA)," ETSI Guide, December 2001.
- [22] C. Chatfield, *The Analysis of Time Series: An Introduction, Sixth Edition (Chapman & Hall/CRC Texts in Statistical Science)*. Chapman and Hall/CRC, 2003.
- [23] G. E. P. Box, G. M. Jenkins, and G. C. Reinsel, *Time Series Analysis: Forecasting and Control (Wiley Series in Probability and Statistics)*. Wiley, 2008.
- [24] C. Chatfield, *Time-Series Forecasting*. Chapman and Hall/CRC, 2000.
- [25] D. M. Levine and D. F. Stephan, *Even You Can Learn Statistics: A Guide for Everyone Who Has Ever Been Afraid of Statistics (2nd Edition)*. FT Press, 2009.
- [26] S. Kullback, *Information theory and statistics*. Peter Smith, 1978.
- [27] N. Wiener, *Cybernetics or control and communication in the animal and the machine*. New York: Wiley, 1948.
- [28] T. M. Cover and J. A. Thomas, *Elements of Information Theory*. Wiley-Interscience, 1991.

- [29] W. J. Dixon and R. A. Kronmal, "The choice of origin and scale for graphs," *J. ACM*, vol. 12, no. 2, 1965.
- [30] P. F. Velleman, "Interactive computing for exploratory data analysis i: display algorithms." *Washington, DC: American Statistical Association.*, 1976.
- [31] H. A. Sturges, "The choice of a class interval," *JASA*, 1926.